


UNIVERSITÉ LIBRE DES PAYS DES GRANDS LACS



BP. 368 GOMA

www.ulpgl.net

DOMAINE DE SCIENCES ET TECHNOLOGIES

FILIÈRE DES SCIENCES DE L'INGÉNIEUR

DÉTECTION AUTOMATIQUE DE L'INFARCTUS DU MYOCARDE À PARTIR D'IMAGES ECG DÉGRADÉES À L'AIDE DE RESEAUX DE NEURONES CONVOLUTIFS

Par **VIVUYA MUNGOSY Djofina**

Travail présenté en vue de l'obtention du Diplôme de
Bachelor en Sciences de l'Ingénieur

Mention : Génie Informatique

Directeur : Prof. ALAIN AKWIR NKIEDIEL

Encadreur : Msc. DANIELLA MUGHOLE

ANNEE ACADEMIQUE 2024 - 2025

Epigraphe

« Artificial intelligence is the new electricity »

Andrew Ng

Dédicace

À notre très chère mère, Kabuo Nzuva Jacqueline, dont la force, les sacrifices et l'amour ont tracé le chemin qui nous a mené jusqu'ici.

VIVUYA MUNGOSY DJOFINA

Remerciements

Nos remerciements s'adressent avant tout à Dieu, le Maître des temps et des circonstances, sans qui ce parcours n'aurait jamais été possible. Il est le Dieu qui pourvoit.

Nous exprimons notre profonde gratitude à notre Directeur de mémoire, le Professeur Alain AKWIR NKIEDIEL, ainsi qu'à notre Encadreur, l'Ingénieure Daniella MUGHOLE KALIMUMBALO, pour leur accompagnement, leurs précieux conseils et leur patience tout au long de ce projet.

Notre reconnaissance s'adresse tout particulièrement à notre mère, KABUO NZUVA Jacqueline. Ce travail est le fruit de sa bravoure et de sa résilience. Si nous sommes arrivés au terme de ce parcours, c'est grâce à son soutien indéfectible et à ses sacrifices quotidiens.

Nous tenons à exprimer notre profonde gratitude à l'organisation Solidarité Bonne Volonté pour son assistance qui a rendu ce projet possible. Nos remerciements vont spécialement à Monsieur Alphonse WASEKA et Monsieur Alfred HEILIGENBRUNNER pour leur précieuse aide et leur confiance en notre potentiel.

À nos frères et sœurs, merci pour votre amour, votre présence et les nombreux sacrifices consentis pour notre réussite. Votre soutien est le socle sur lequel nous avons bâti nos efforts.

À nos amis et collègues, nous disons merci pour le soutien moral, les conseils avisés et l'aide technique et intellectuelle partagées tout au long de ces années. Votre camaraderie a rendu ce chemin moins ardu.

Enfin, que tous ceux qui, de près ou de loin, ont contribué à la réalisation de ce travail, trouvent ici l'expression de notre sincère gratitude.

VIVUYA MUNGOSY DJOFINA

Résumé

Ce mémoire porte sur l'utilisation des techniques d'apprentissage profond pour la détection automatique de l'infarctus du myocarde à partir d'images d'électrocardiogrammes (ECG). L'objectif principal de ce travail est d'explorer la capacité des modèles de vision par ordinateur à analyser des images ECG et à identifier des signes associés à l'infarctus du myocarde. L'étude s'appuie sur un jeu de données public d'images ECG à 12 dérivations issu de la PTB-XL Database. Une approche basée sur l'architecture ConvNeXt a été mise en œuvre pour classifier les images en deux catégories : infarctus du myocarde (MI) et sujets normaux (NORM). Afin d'améliorer la performance et la robustesse du modèle, différentes stratégies d'apprentissage ont été mises en œuvre, notamment l'augmentation de données et l'utilisation de la focal loss. Les résultats expérimentaux montrent que le modèle développé est capable d'atteindre de bonnes performances de classification tout en conservant une certaine robustesse face à différentes dégradations visuelles des images ECG. Enfin, une application web nommée CardioVision-MI a été développée afin d'illustrer l'intégration du modèle dans un outil interactif d'aide au diagnostic. Les résultats obtenus mettent en évidence le potentiel des approches d'apprentissage profond pour assister l'analyse des électrocardiogrammes et contribuer au développement d'outils d'aide à la décision en cardiologie.

Mots-clés : électrocardiogramme (ECG), infarctus du myocarde, apprentissage profond, vision par ordinateur, classification d'images médicales, ConvNeXt.

Abstract

This thesis explores the use of deep learning techniques for the automatic detection of myocardial infarction from electrocardiogram (ECG) images. The main objective of this work is to investigate the ability of computer vision models to analyze ECG images and identify patterns associated with myocardial infarction. The study is based on a public dataset of standard 12-lead ECG images derived from the PTB-XL Database. A ConvNeXt-based architecture was implemented to classify ECG images into two categories: myocardial infarction (MI) and normal subjects (NORM). To improve both performance and robustness, several training strategies were investigated, including data augmentation and the use of Focal Loss. Experimental results demonstrate that the proposed model achieves strong classification performance while maintaining robustness against various visual degradations affecting ECG images. In addition, a web application named CardioVision-MI was developed to demonstrate the integration of the model into an interactive clinical decision-support tool. The findings highlight the potential of deep learning approaches to assist ECG interpretation and contribute to the development of computer-aided diagnostic systems in cardiology.

Keywords: electrocardiogram (ECG), myocardial infarction, deep learning, computer vision, medical image classification, ConvNeXt.

Table des matières

Epigraphe	i
Dédicace.....	ii
Remerciements.....	iii
Résumé.....	iv
Sigles et abréviations	x
Liste des tableaux.....	xi
Liste des équations.....	xii
Liste des figures	xiii
0. Introduction générale	1
0.1. Généralités sur le thème	1
0.2. Identification et formulation du problème	1
0.3. Questions de recherche.....	2
0.4. Formulation des hypothèses	3
0.5. Justification du choix du sujet et motivations	3
0.6. Énoncé des objectifs de recherche	4
0.6.1. L'objectif général.....	4
0.6.2. Les objectifs opérationnels	4
0.7. Méthodologie et délimitation du travail	5
0.8. Structure du mémoire/ Subdivision du travail.....	5
Chapitre 1 Fondements Théoriques et État de l'Art.....	7
1.1 Introduction partielle	7
1.2 Anatomie et fonctionnement du cœur	7
1.2.1 Structure anatomique	7
1.2.2 Fonctionnement mécanique du cœur	8

1.2.3	Activité électrique du cœur	9
1.2.4	Système de conduction cardiaque	10
1.2.5	Principe de l'électrocardiographie moderne et ECG à 12 dérivations	11
1.3	L'Infarctus du Myocarde : Physiopathologie et Manifestations ECG	14
1.3.1	Physiopathologie de l'infarctus du myocarde	15
1.3.2	Manifestations de l'infarctus du myocarde sur l'ECG	16
1.3.3	Intérêt du diagnostic automatique de l'infarctus à partir des images ECG	18
1.4	Notions de Machine Learning et Deep Learning	19
1.4.1	Machine Learning	19
1.4.2	Deep Learning	20
1.4.3	Réseaux de Neurones Convolutifs (CNN)	21
1.5	Détection automatique de l'Infarctus du Myocarde : État de l'art	22
1.5.1	Approches classiques d'apprentissage automatique	22
1.5.2	Apprentissage profond et modèles convolutifs	23
1.5.3	Problème de robustesse et conditions réelles	23
1.6	Conclusion partielle	24
Chapitre 2 Méthodologie et Mise en œuvre		25
2.1	Introduction partielle	25
2.2	Matériel : Données et Corpus	25
2.2.1	Dataset PTB-XL : Présentation Générale et Annotations Diagnostiques	25
2.2.2	Construction du Corpus : de la sélection clinique à l'image ECG	26
2.2.3	Corpus de robustesse : l'épreuve des données dégradées	27
2.2.4	Synthèse du dataset d'entraînement	28
2.3	Prétraitement des images ECG	28
2.3.1	Pipeline d'entraînement	28
2.3.2	Pipeline de Validation et de test	29
2.4	Architecture du modèle de classification	29
2.4.1	Choix de l'architecture : ConvNeXt-Small	29
2.5	Protocole d'entraînement du modèle	31

2.5.1	Configuration d'optimisation et Fonction de Perte.....	31
2.5.2	Stratégie de suivi et précision mixte	32
2.5.3	Seuil de décision et sécurité clinique	32
2.6	Méthodes d'évaluation des performances	33
2.6.1	Analyse quantitative : Matrice de confusion et métriques dérivées	33
2.6.2	Courbe ROC et aire sous la courbe.....	34
2.7	Interprétabilité du modèle par cartes d'activation.....	34
2.7.1	Fonctionnement technique	34
2.7.2	Validation de la cohérence clinique	35
2.8	Évaluation de la robustesse et de la généralisation	35
2.9	Conception du système d'aide au diagnostic ECG	35
2.9.1	Objectif du système.....	35
2.9.2	Architecture fonctionnelle et logicielle.....	36
2.9.3	Diagramme des cas d'utilisation.....	37
2.9.4	Diagramme de classes.....	40
2.9.5	Diagramme d'activité globale.....	41
2.10	Conclusion partielle	42
Chapitre 3 Expérimentations, Analyse des Résultats et Discussion		43
3.1	Introduction partielle	43
3.2	Protocole Expérimental	43
3.2.1	Configuration matérielle	43
3.2.2	Paramètres finaux du modèle baseline.....	43
3.2.3	Scénarios expérimentaux	45
3.3	Résultats du modèle Baseline.....	45
3.3.1	Performances globales sur le jeu de test interne	45
3.3.2	Analyse qualitative de l'attention du modèle.....	47
3.3.3	Limites observées avec le modèle Baseline.....	48
3.3.4	Analyse qualitative via Grad-CAM	48
3.3.5	Discussion : limites du modèle baseline	49

3.4	Optimisation du modèle	50
3.4.1	Impact de la Data Augmentation	52
3.4.2	Introduction de la Focal Loss.....	54
3.5	Analyse comparative du comportement probabiliste des modèles	55
3.5.1	Distribution des probabilités prédictives	55
3.5.2	Analyse de la confiance des prédictions	57
3.5.3	Calibration probabiliste du modèle	60
3.6	Robustesse clinique du modèle	61
	Performance par type de dégradation	61
3.7	Démonstration du système CardioVision-MI	65
3.7.1	Authentification des utilisateurs	65
3.7.2	Tableau de bord.....	65
3.7.3	Gestion des patients	66
3.7.4	Analyse automatisée des ECG	67
3.7.5	Génération de rapports.....	67
3.8	Conclusion partielle.....	68
	Conclusion générale.....	69
	Annexe A Extraits de l'implémentation du modèle d'intelligence artificielle...	70
A.1	Configuration des hyperparamètres	70
A.2	Pipeline de prétraitement et de Data Augmentation.....	70
A.3	Implémentation de la fonction de perte Focal Loss utilisée lors de l'entraînement..	71
A.4	Boucle d'entraînement	71
	Annexe B Interface de la plateforme CardioVision-MI	72
B.1	Interface principale.....	72
B.2	Gestion des rendez-vous.....	72
B.3	Statistiques	73
	Bibliographie.....	74

Sigles et abréviations

AI	Artificial Intelligence
AMP	Automatic Mixed Precision
AUC	Area Under the Curve
BCE	Binary Cross Entropy
BCEWithLogitsLoss	Binary Cross Entropy with Logits Loss
CNN	Convolutional Neural Network
DL	Deep Learning
ECG	Electrocardiogram
ECE	Expected Calibration Error
F1-Score	Harmonic Mean of Precision and Recall
FL	Focal Loss
GPU	Graphics Processing Unit
Grad-CAM	Gradient-weighted Class Activation Mapping
LR	Learning Rate
MI	Myocardial Infarction
NORM	Normal Electrocardiogram
OMS	Organisation Mondiale de la Santé
PTB-XL	PTB-XL Electrocardiography Database
QRS	QRS Complex
ReLU	Rectified Linear Unit
ROC	Receiver Operating Characteristic
RGB	Red Green Blue
ST	ST Segment
TNR	True Negative Rate (Spécificité)
TPR	True Positive Rate (Sensibilité)
TPU	Tensor Processing Unit
XAI	Explainable Artificial Intelligence
VRAM	Video Random Access Memory

Liste des tableaux

Tableau 1-1 Caractéristiques normales de l'ECG.....	14
Tableau 2-1 Composition du corpus de robustesse constitué d'images ECG dégradé.	27
Tableau 2-2 Répartition des échantillons du corpus d'apprentissage (PTB-XL).....	28
Tableau 2-3 Documentation du cas d'utilisation principal : Lancer Analyse ECG.....	40
Tableau 3-1 Hyperparamètres et configuration technique du modèle baseline.....	44
Tableau 3-2 Performances du modèle Baseline sur le jeu de test.....	46
Tableau 3-3 Comparaison des configurations.....	52

Liste des équations

Équation 2-1 $FL_{pt} = -\alpha t1 - pty\log(pt)$	31
Équation 2-2 $J\omega = \omega \times Sensibilité + Spécificité - 1$	33
Équation 2-3 $F1 = 2 \times Précision \times Sensibilité / Précision + Sensibilité$	34
Équation 2-4 $Précision = VPVP + P$	34

Liste des figures

Figure 1-1 Schéma anatomique du cœur humain	8
Figure 1-2 Phases du cycle cardiaque	9
Figure 1-3 Schéma du système de conduction électrique du cœur	11
Figure 1-4 Positionnement des électrodes pour l'ECG à 12 dérivation	12
Figure 1-5 ECG standard à 12 dérivation	13
Figure 1-6 Représentation d'une ischémie cardiaque par obstruction artérielle	15
Figure 1-7 Principales modifications morphologiques du tracé ECG lors d'un infarctus.	17
Figure 1-8 Comparaison entre les méthodes traditionnelles et basées sur le Deep Learning..	20
Figure 1-9 Opération de convolution	20
Figure 1-10 Architecture typique d'un réseau de neurones convolutif (CNN)	21
Figure 2-1 Transformation des données : du signal ECG brut vers le corpus d'images	27
Figure 2-2 Architecture détaillée du modèle ConvNeXt.	30
Figure 2-3 Comportement de la Focal Loss en fonction de la probabilité de la classe réelle .	32
Figure 2-4 Diagramme de cas d'utilisation du système	39
Figure 2-5 Diagramme de classes du système	41
Figure 2-6 Diagramme d'activité globale du système	42
Figure 3-1 Matrice de confusion et Courbe ROC du modèle Baseline	46
Figure 3-2 Visualisation Grad-CAM du modèle Baseline	47
Figure 3-3 Performance du modèle selon le type de dégradation des images ECG.	48
Figure 3-4 Grad-CAM sur ECG fortement dégradé	49
Figure 3-5 Évolution de la perte d'entraînement et de validation	51
Figure 3-6 Matrices de confusion au seuil optimal pour l'évaluation du diagnostic.	51
Figure 3-7 Échantillons d'entraînement après Data Augmentation	53
Figure 3-8 Comparaison des cartes Grad-CAM	54
Figure 3-9 Distribution des probabilités prédictives du modèle Baseline.	56
Figure 3-10 Distribution des probabilités prédictives du modèle final	57
Figure 3-11 Distribution de la confiance pour les prédictions correctes et incorrectes	58

Figure 3-12 Distribution de la confiance pour les prédictions correctes et incorrectes.....	59
Figure 3-13 Diagramme de fiabilité du modèle Baseline.	60
Figure 3-14 Diagramme de fiabilité du modèle final.....	61
Figure 3-15 Fiabilité du diagnostic selon le type de dégradation.	62
Figure 3-16 Visualisation Grad-CAM du modèle final sur différentes conditions	64
Figure 3-17 Interface d'authentification de l'application	65
Figure 3-18 Tableau de bord de l'application.....	66
Figure 3-19 Interface de gestion des patients	66
Figure 3-20 Exemple d'analyse ECG avec visualisation Grad-CAM	67
Figure 3-21 Exemple de rapport généré par l'application	68
Figure 3-22 Configuration des hyperparamètres	70
Figure 3-23 Pipeline de prétraitement et de Data Augmentation	70
Figure 3-24 Implémentation de la fonction de perte Focal Loss	71
Figure 3-25 Boucle d'entraînement	71
Figure 3-26 Interface principale.....	72
Figure 3-27 Interface de gestion des rendez-vous	72
Figure 3-28 Interface des Statistiques.....	73

0. Introduction générale

0.1. Généralités sur le thème

Les maladies cardiovasculaires demeurent une cause majeure de décès dans le monde, faisant environ 17,9 millions de victimes chaque année, selon le rapport de l'Organisation Mondiale de la Santé (OMS) [1]. Parmi elles, l'infarctus du myocarde (MI) constitue une urgence vitale où chaque minute compte pour limiter la nécrose du muscle cardiaque. L'électrocardiogramme (ECG) à 12 dérivations est l'outil diagnostique de référence pour identifier les signes d'ischémie [2].

L'ECG est un examen non invasif et indolore qui permet de visualiser l'activité électrique du cœur et ainsi permettre de détecter ces anomalies. Traditionnellement, son analyse requiert l'expertise de cardiologues pour une interprétation fiable des tracés des ondes (P, QRS, T) et des intervalles. Cependant, face au volume croissant d'enregistrements et à la complexité de leur analyse manuelle, les techniques de classification automatique, notamment le Deep Learning (DL), deviennent des outils essentiels [3].

De plus, malgré l'essor des ECG numériques, une part importante des enregistrements existe toujours sous forme des tracés papiers, des photographies ou des scans, en particulier dans les régions moins équipées. Ces formats physiques sont difficiles à intégrer dans des systèmes informatisés et peuvent être altérés par des bruits, des plis, des taches ou une mauvaise qualité de capture, ce qui rend leur interprétation automatisée particulièrement complexe [4].

Dans ce contexte, l'intelligence artificielle (IA), et plus spécifiquement les réseaux de neurones convolutifs (CNN), se révèlent être des outils puissants pour l'analyse d'images. L'application des CNN à l'étude des images offre une opportunité unique d'automatiser et d'accélérer le diagnostic de l'infarctus du myocarde (MI). L'objectif de ce travail est de mettre en œuvre et évaluer un modèle d'apprentissage profond basé sur l'architecture ConvNeXt afin de détecter l'infarctus sur des images d'ECG, tout en étudiant sa capacité de résistance aux diverses imperfections visuelles introduites lors de l'acquisition.

0.2. Identification et formulation du problème

Malgré les avancées technologiques en cardiologie, une part importante des électrocardiogrammes (ECG) dans le monde, notamment en Afrique et dans d'autres pays

en développement, est encore produite et stockée sous forme de tracés papier ou de captures numériques indirectes (photographies, scans) [4]. Ces supports physiques demeurent essentiels pour le diagnostic d'urgence, particulièrement pour l'identification rapide de l'infarctus du myocarde.

Le problème réside dans le fait que l'analyse manuelle de ces tracés par des experts est chronophage et sujette à l'erreur humaine sous pression. De plus, l'intégration de ces documents dans des systèmes de santé numériques est complexe. Les images d'ECG papier sont souvent de qualité dégradée : elles présentent du bruit, des plis, des taches, ou des distorsions de perspective liées à une prise de vue sur smartphone ou écran. Ces artefacts visuels masquent les motifs cruciaux (tels que le segment ST ou l'onde Q), rendant l'interprétation par des algorithmes classiques particulièrement difficile [4].

Notre objectif est de développer un modèle d'apprentissage profond (un CNN) capable de détecter l'infarctus sur des images d'ECG, tout en étudiant sa capacité de résistance aux diverses imperfections visuelles introduites lors de l'acquisition. Il s'agit non seulement de classer la pathologie, mais aussi d'évaluer la stabilité du diagnostic face à la dégradation du support physique pour garantir une utilisation clinique sécurisée.

0.3. Questions de recherche

Pour résoudre le problème identifié et atteindre notre objectif, une question se pose :

Comment mettre en œuvre et optimiser un modèle de réseau de neurones convolutif capable de diagnostiquer l'infarctus du myocarde à partir d'images ECG, tout en garantissant une fiabilité acceptable face aux artefacts visuels du monde réel ?

Cette question centrale, nous amène à explorer les questions complémentaires suivantes :

1. Quelle est l'efficacité d'un modèle de réseau de neurones convolutif pour classer l'infarctus du myocarde à partir d'images ECG numériques pures ?
2. Dans quelle mesure la présence d'artefacts (bruit, taches, distorsions) dégrade-t-elle la performance du modèle, et à partir de quel niveau de dégradation le diagnostic devient-il instable ?
3. Quelles stratégies algorithmiques et techniques d'optimisation permettent de stabiliser le diagnostic et de garantir une fiabilité clinique acceptable sur des supports dégradés ?

0.4. Formulation des hypothèses

En réponse aux questions de recherche posées, nous formulons les hypothèses suivantes, qui seront testées, confirmées ou nuancées au cours de ce projet par l'expérimentation et la simulation :

1. Nous postulons qu'un modèle d'apprentissage profond, entraîné sur des images ECG standardisées, devrait atteindre une sensibilité élevée pour la détection des signes d'infarctus.
2. Nous émettons l'hypothèse que la performance du modèle subirait une baisse proportionnelle à l'intensité des artefacts, entraînant une instabilité du diagnostic sur les supports les plus dégradés.
3. Nous supposons que la combinaison d'une augmentation de données ciblée, de fonctions de perte spécifiques et d'un seuillage de décision adapté permettrait de réduire l'instabilité du modèle.

0.5. Justification du choix du sujet et motivations

Le domaine de l'intelligence artificielle (IA) appliquée à la santé, particulièrement en cardiologie, représente aujourd'hui un enjeu de santé publique majeur. Si l'électrocardiogramme (ECG) demeure un outil diagnostique vital, son potentiel est souvent limité par la persistance des formats papier et leur dégradation physique, une réalité prépondérante en République Démocratique du Congo (RDC) ainsi que dans de nombreux pays émergents [4].

Notre motivation pour ce sujet est née de la volonté de mettre l'IA au service de l'automatisation de l'interprétation d'images ECG imparfaites. L'objectif est d'offrir un impact direct sur la rapidité de prise en charge des urgences cardiaques, notamment l'infarctus du myocarde, là où l'expertise cardiologique peut faire défaut.

Scientifiquement, ce projet répond à un défi actuel : rendre les réseaux de neurones convolutifs (CNN) robustes face aux artefacts visuels réalistes (bruit, plis, taches) présents sur les ECG scannés ou photographiés. Le PhysioNet Challenge 2024 confirme la pertinence de cette problématique. En soumettant un modèle entraîné sur des données numériques à des simulations de dégradations physiques, nous analysons ses limites de généralisation afin de proposer des optimisations capables de stabiliser le diagnostic [4].

Socialement, cette recherche peut améliorer significativement l'accès au diagnostic dans les zones reculées, aider les praticiens, valoriser les vastes archives existantes et alléger la charge de travail, apportant ainsi une solution concrète à un problème de santé publique.

0.6. Énoncé des objectifs de recherche

0.6.1. L'objectif général

L'objectif général de cette recherche est de mettre en œuvre et évaluer un modèle de classification d'images basé sur les réseaux de neurones convolutifs (CNN) capable de détecter l'infarctus du myocarde à partir d'images d'électrocardiogrammes (ECG), tout en garantissant sa fiabilité décisionnelle face aux artefacts visuels et aux dégradations typiques des supports physiques.

0.6.2. Les objectifs opérationnels

Pour atteindre cet objectif, ce projet se fixe les objectifs opérationnels suivants :

Phase 1 : Développement du modèle de référence (Baseline)

- Collecter et standardiser un dataset d'images ECG numériques pour servir de base d'apprentissage.
- Adapter et entraîner une architecture CNN préexistante pour la classification binaire de l'infarctus du myocarde.
- Établir une référence de performance sur des données "propres" (Accuracy, Recall, F1-score).

Phase 2 : Évaluation de la robustesse

- Constituer un corpus de robustesse indépendant composé d'images ECG dégradées (scans, photos mobiles, documents froissés) issues du challenge de numérisation [4].
- Soumettre le modèle à l'épreuve de ces données dégradées (exclues de tout entraînement) pour mesurer la chute de performance liée au support physique.
- Analyser l'instabilité décisionnelle du modèle face à ces conditions réelles.

Phase 3 : Optimisation et sécurisation clinique

- Intégrer des mécanismes de régularisation : utilisation de l'augmentation de données ciblée et de fonctions de perte spécifiques (Focal Loss) pour stabiliser l'apprentissage.

- Optimiser le seuil de décision (Indice de Youden pondéré) pour privilégier la sensibilité diagnostique et garantir la sécurité du patient sur les supports dégradés.
- Comparer la fiabilité finale du modèle optimisé par rapport à la version de base sur le corpus de robustesse.

0.7. Méthodologie et délimitation du travail

Ce projet adoptera une méthodologie expérimentale et itérative, centrée sur l'apprentissage profond, pour entraîner un modèle de classification d'images ECG. Nous réaliserons d'abord un état de l'art, collecterons et préparerons des données claires et des données artificiellement dégradées, entraînerons un modèle CNN, puis évaluerons et analyserons ses performances. Le tout sera implémenté en Python avec des bibliothèques d'apprentissage profond.

Afin de maintenir le projet réalisable dans le cadre d'un mémoire de licence, ce travail se limite à l'analyse d'images statiques d'ECG à 12 dérivations présentées dans un format standard composé de trois lignes et quatre colonnes, accompagnées d'une dérivation longue correspondant à la dérivation II, dans l'objectif de détecter des signes d'infarctus du myocarde. Les artefacts visuels étudiés sont restreints à ceux pouvant être simulés dans des conditions contrôlées, et les conclusions du travail restent de nature exploratoire, sans constituer un dispositif médical certifié.

0.8. Structure du mémoire/ Subdivision du travail

Hormis l'introduction générale et la conclusion générale, ce travail est constitué de trois chapitres principaux :

Chapitre 1 : Fondements Théoriques et État de l'Art

Ce chapitre pose les fondements théoriques nécessaires à la compréhension du projet, en abordant les notions de l'électrocardiographies, de l'infarctus du myocarde, et les principes de l'apprentissage profond et des réseaux de neurones de convolutifs.

Chapitre 2 : Méthodologie et Mise en œuvre

Ce chapitre expose la préparation du jeu de données (filtrage, normalisation et gestion du déséquilibre), le pipeline d'entraînement du modèle de vision par ordinateur, ainsi que la conception fonctionnelle et statique de l'application d'aide au diagnostic.

Chapitre 3 : Modélisation, Expérimentations et analyse des Résultats.

Ce chapitre expose l'implémentation technique du modèle et du système logiciel. Il présente une analyse critique des performances face aux artefacts et valide la fiabilité clinique de la solution finale.

Chapitre 1

Fondements Théoriques et État de l'Art

1.1 Introduction partielle

Le présent chapitre a pour objectif de poser les fondements théoriques et conceptuels nécessaires à la compréhension de notre projet de recherche. Dans un premier temps, l'électrocardiogramme sera présenté ; ensuite nous décrirons la physiopathologie de l'infarctus du myocarde (MI), qui constitue le cœur de notre étude ; après quoi nous explorerons les notions de Machine Learning et de Deep Learning. Enfin, nous présenterons un état de l'art des méthodes de détection automatique de l'infarctus du myocarde, en nuancant les approches basées sur l'analyse des signaux temporels et celles s'appuyant sur les images.

1.2 Anatomie et fonctionnement du cœur

Le cœur est un organe vital, creux et musculaire, situé au centre du thorax, derrière le sternum et légèrement orienté vers la gauche. D'une taille approximative à celle d'un poing, il agit comme une pompe assurant la circulation continue du sang dans l'organisme [5] [6]. Par son activité rythmique, il permet l'apport d'oxygène et de nutriments aux tissus tout en participant à l'élimination du dioxyde de carbone et des déchets métaboliques. Le bon fonctionnement du système cardiovasculaire dépend donc étroitement de l'intégrité anatomique et physiologique du cœur.

1.2.1 Structure anatomique

Le cœur est divisé en quatre cavités : deux oreillettes situées à la partie supérieure et deux ventricules à la partie inférieure, séparées par le septum cardiaque.

- **L'oreillette droite** reçoit le sang désoxygéné provenant de la circulation systémique par les veines caves supérieure et inférieure, tandis que l'oreillette gauche reçoit le sang oxygéné issu des poumons via les veines pulmonaires [5] [6].
- **Le ventricule droit (VD)** éjecte ce sang vers les poumons par l'artère pulmonaire. C'est la petite circulation, ou circulation pulmonaire.
- **Le ventricule gauche (VG)**, doté d'une paroi plus épaisse en raison de la pression plus importante qu'il doit générer, propulse le sang oxygéné dans l'aorte, assurant ainsi la **grande circulation** systémique.




Figure 1-1 Schéma anatomique du cœur humain, adapté de [7].

Chaque oreillette communique avec son ventricule par une **valve auriculo-ventriculaire** : la valve tricuspide à droite et la valve mitrale à gauche. Deux autres valves, dites **sigmoïdes**, régulent la sortie du sang : la valve pulmonaire et la valve aortique. Leur ouverture et leur fermeture, purement passives, dépendent des différences de pression entre les cavités et garantissent une circulation unidirectionnelle, empêchant tout reflux sanguin [5] [6].

1.2.2 Fonctionnement mécanique du cœur

Le fonctionnement du cœur repose sur un **cycle cardiaque** qui se répète environ 70 à 80 fois par minute chez un adulte au repos [5] [6]. Chaque cycle comprend trois phases principales : la diastole, la systole auriculaire et la systole ventriculaire. Ces phases traduisent l'alternance coordonnée des contractions et relâchements des cavités cardiaques [5] [6].

1. **La diastole** correspond à la phase de relaxation du myocarde. Dans un premier temps (diastole isovolumétrique), la pression dans les ventricules chute, provoquant la fermeture des valves sigmoïdes. Lorsque la pression ventriculaire devient inférieure à celle des oreillettes, les valves auriculo-ventriculaires s'ouvrent, permettant le remplissage passif des ventricules (diastole isotonique).




Figure 1-2 Phases du cycle cardiaque [8].

2. **La systole auriculaire** débute lorsque les oreillettes se contractent, complétant le remplissage des ventricules. Cette contraction modérée augmente légèrement la pression intra-auriculaire et transfère le sang résiduel dans les ventricules.
3. **La systole ventriculaire** suit immédiatement. Les ventricules se contractent (systole isovolumétrique) : la pression augmente jusqu'à dépasser celle des artères, entraînant l'ouverture des valves sigmoïdes et l'éjection du sang vers l'aorte et l'artère pulmonaire (systole isotonique).

À la fin de l'éjection, le relâchement des ventricules provoque la fermeture des valves sigmoïdes, marquant le début d'un nouveau cycle [5] [6]. Ces alternances de pressions et de volumes permettent un flux sanguin continu et rythmé dans l'ensemble du corps.

1.2.3 Activité électrique du cœur

L'activité mécanique du cœur est commandée par une activité électrique intrinsèque générée et propagée dans le myocarde [5] [6]. Ce phénomène repose sur les échanges ioniques de sodium (Na^+), de potassium (K^+) et de calcium (Ca^{2+}) à travers la membrane cellulaire des cardiomyocytes, via des canaux ioniques spécialisés [5] [6]. Ces mouvements

ioniques entraînent une variation du potentiel de membrane appelée potentiel d'action, qui déclenche la contraction des fibres musculaires.

On distingue deux grands types de cellules cardiaques [5] [6] :

- Les **myocytes contractiles**, responsables de la contraction du muscle cardiaque ;
- Les **cellules pacemaker**, localisées principalement dans le nœud sino-auriculaire (NSA), qui initient spontanément les impulsions électriques.

Cette activité électrique, initiée dans le nœud sinusal et propagée de manière ordonnée à travers le cœur, constitue la base de l'électrocardiogramme (ECG).

La prochaine section abordera donc le système de conduction cardiaque et la formation du signal ECG, essentiels pour comprendre l'analyse des tracés ECG.

1.2.4 Système de conduction cardiaque

La forme et la durée des potentiels d'action dépendent des propriétés locales du tissu cardiaque, notamment la nature des canaux ioniques présents dans la membrane cellulaire, la conductivité électrique ainsi que la courbure du front d'onde. Ainsi, à chaque battement, une onde de dépolarisation se propage dans le cœur, suivie par la repolarisation des cellules [5] [6].

Sur le plan physiologique, chaque battement cardiaque normal débute dans le nœud sino-auriculaire (NSA), situé dans l'oreillette droite et constitué principalement de cellules pacemaker. Le potentiel d'action généré y entraîne la dépolarisation des cellules voisines, avant de se propager dans la paroi auriculaire gauche jusqu'au nœud auriculo-ventriculaire (NAV). Ce dernier, également composé de cellules pacemaker, retarde la conduction afin de permettre la contraction complète des oreillettes. Il peut aussi prendre le relais de l'activité électrique en cas de dysfonction du NSA.

À partir du NAV, le signal électrique se propage rapidement le long du faisceau de His, qui traverse le septum interventriculaire, puis se divise en deux branches droite et gauche. Ces dernières conduisent l'influx vers l'apex des ventricules avec une grande rapidité. Finalement, les fibres de Purkinje distribuent l'onde de dépolarisation à l'ensemble des parois ventriculaires, assurant ainsi une contraction mécanique synchrone [5] [6].




Figure 1-3 Schéma du système de conduction électrique du cœur [9].

Lorsqu'on place des électrodes à la surface du thorax, le signal enregistré par rapport à une référence constitue l'électrocardiogramme (ECG). Ce tracé reflète la somme des variations de potentiel générées par l'ensemble des cellules cardiaques. L'ECG normal se caractérise par trois ondes principales [5] [6] :

- **L'onde P**, correspondant à la dépolarisation et la contraction auriculaires ;
- **Le complexe QRS**, représentant la dépolarisation et la contraction ventriculaires ;
- **L'onde T**, qui traduit la repolarisation ventriculaire.

La morphologie de ces ondes, notamment les variations d'amplitude du segment ST et la polarité de l'onde T, constitue le marqueur diagnostique prédominant pour l'identification de l'infarctus du myocarde.

1.2.5 Principe de l'électrocardiographie moderne et ECG à 12 dérivations

L'électrocardiographie consiste à enregistrer l'activité électrique du cœur sur une période de temps grâce à des signaux captés par des électrodes placées à la surface du thorax [5] [7]. Elle s'est imposée comme un outil fondamental dans le diagnostic et la surveillance des pathologies cardiaques, en raison de son caractère non invasif, peu coûteux et facile à utiliser.

Un électrocardiogramme (ECG) permet notamment d'identifier différentes anomalies électriques et structurelles cardiaques, parmi lesquelles [5] [7]:

- Les arythmies : perturbations du système électrique cardiaque ;
- La maladie coronarienne : obstruction partielle de l'apport sanguin dans les artères par des dépôts graisseux ;

- L'infarctus du myocarde : interruption brutale de l'irrigation sanguine du cœur ;
- Les cardiomyopathies : épaissement ou dilatation anormale du muscle cardiaque.

L'ECG correspond à une projection des potentiels électriques cardiaques, appelés dérivations, sur des axes spécifiques dépendant de la position des électrodes. Chaque dérivation fournit une vue particulière de l'activité cardiaque sous un certain angle du corps. Depuis les recommandations de l'American Heart Association en 1954, l'ECG à 12 dérivations est devenu la norme clinique [5] [6]. Il repose sur l'utilisation de 10 électrodes, placées comme suit (Figure 1-4 Positionnement des électrodes pour l'ECG à 12 dérivations.) :




Figure 1-4 Positionnement des électrodes pour l'ECG à 12 dérivations [25].

- **V1** : 4e espace intercostal, à droite du sternum ;
- **V2** : 4e espace intercostal, à gauche du sternum ;
- **V3** : à mi-distance entre V2 et V4 ;
- **V4** : 5e espace intercostal, sur la ligne médio-claviculaire ;
- **V5** : ligne axillaire antérieure, au même niveau que V4 ;
- **V6** : ligne axillaire moyenne, au même niveau que V4 et V5 ;
- **RL** : au-dessus de la cheville et en dessous du tronc (jambe droite) ;
- **RA** : entre l'épaule et le coude (bras droit) ;
- **LL** : au-dessus de la cheville et en dessous du tronc (jambe gauche) ;

- **LA** : entre l'épaule et le coude (bras gauche).




Figure 1-5 ECG standard à 12 dérivations : en bleu, les données mesurées ; en noir, l'ECG simulé d'après les temps d'activation et de récupération estimés [47].

Cette configuration permet de visualiser l'activité cardiaque sous 12 angles différents.

Les dérivations sont regroupées en trois catégories principales :

- 6 dérivations précordiales : V1 à V6 ;
- 3 dérivations des membres bipolaires :
 - $I = LA - RA$
 - $II = LL - RA$
 - $III = LL - LA$
- 3 dérivations unipolaires augmentées : aVR, aVL, aVF.

Les caractéristiques normales d'un ECG sont résumées dans le Tableau 1-1 Caractéristiques normales de l'ECG., incluant notamment la fréquence cardiaque (60–100 bpm), la durée de l'onde P (<110 ms), de l'intervalle PR (112–120 ms), du complexe QRS (70–100 ms), ainsi que les particularités de l'intervalle QT, du segment ST et de l'onde T.

Comme introduit en section 1.2.4, un ECG comporte trois ondes principales (P, QRS, T) et quatre segments essentiels (Figure 1-3 Schéma du système de conduction électrique du cœur.). L'amplitude, la durée et la polarité de ces ondes et segments constituent des indicateurs diagnostiques majeurs pour la détection des anomalies cardiaques.

Tableau 1-1 Caractéristiques normales de l'ECG [5] [6].

Onde / Intervalle	Durée normale	Amplitude normale	Signification physiologique
Onde P	0,08 – 0,10 s	$\leq 0,25$ mV	Dépolarisation auriculaire
Intervalle PR	0,12 – 0,20 s	—	Conduction auriculo-ventriculaire (du nœud sinusal aux ventricules)
Complexe QRS	0,06 – 0,10 s	$\leq 1,5$ mV en dérivations standard	Dépolarisation ventriculaire
Segment ST	Isoélectrique	—	Début de la repolarisation ventriculaire.
Onde T	0,10 – 0,25 s	$\leq 0,5$ mV en dérivations standard	Repolarisation ventriculaire
Intervalle QT	0,36 – 0,44 s (corrigé selon fréquence cardiaque)	—	Temps total de dépolarisation et repolarisation ventriculaire
Fréquence cardiaque normale	60 – 100 battements/min	—	Rythme sinusal normal

1.3 L'Infarctus du Myocarde : Physiopathologie et Manifestations ECG

L'infarctus du myocarde correspond à la destruction d'une partie du muscle du cœur lorsque celle-ci ne reçoit plus suffisamment de sang et d'oxygène pendant un certain temps. Cette situation se produit généralement lorsqu'une artère coronaire, c'est-à-dire un vaisseau sanguin qui nourrit le cœur, est brusquement bloquée. Le sang ne pouvant plus circuler correctement, la zone concernée du muscle cardiaque souffre d'un manque d'oxygène (ischémie), puis les cellules finissent par mourir : on parle alors de nécrose du myocarde [12].

Cette atteinte du muscle cardiaque est grave car elle réduit la capacité du cœur à pomper le sang correctement et peut provoquer des complications comme des battements irréguliers, une baisse de la fonction cardiaque ou un arrêt cardiaque dans les cas sévères [2]. Pour cette raison, il est très important de détecter rapidement un infarctus. L'électrocardiogramme (ECG), déjà présenté dans les sections précédentes, est l'un des principaux outils utilisés pour le diagnostic. Il permet d'observer les modifications du signal électrique du cœur provoquées par le manque d'oxygène dans le muscle cardiaque, ce qui aide les médecins à reconnaître rapidement la situation [12] [13].

1.3.1 Physiopathologie de l'infarctus du myocarde

La physiopathologie de l'infarctus du myocarde décrit le mécanisme par lequel une partie du muscle cardiaque est endommagée à cause d'un manque prolongé d'apport sanguin. Dans la majorité des cas, le processus commence par l'obstruction d'une artère coronaire, qui est chargée d'alimenter le cœur en oxygène et en nutriments. Cette obstruction est souvent due à la formation d'un caillot sanguin sur une zone déjà rétrécie du vaisseau. Lorsque le flux sanguin est interrompu, la région du myocarde située en aval ne reçoit plus assez d'oxygène : c'est l'ischémie [12].




Figure 1-6 Représentation d'une ischémie cardiaque par obstruction artérielle [14].

Si cette privation d'oxygène dure trop longtemps, les cellules du muscle cardiaque ne peuvent plus produire l'énergie nécessaire à leur fonctionnement. Leur activité électrique et mécanique se dégrade progressivement. Sans rétablissement rapide de la circulation, ces cellules finissent par mourir : on parle alors de nécrose. Cette zone nécrosée ne participe plus correctement à la contraction du cœur, ce qui diminue la performance globale de pompage [12] [13].

Sur le plan électrique, cette souffrance du tissu cardiaque perturbe la propagation normale du signal électrique dans le cœur. Les zones touchées conduisent mal le courant ou ne le conduisent plus du tout. Cela entraîne des modifications visibles sur le tracé ECG, notamment au niveau des segments et des ondes déjà décrits précédemment. Ces changements électriques sont la base de la détection de l'infarctus par analyse de l'ECG, qu'elle soit faite par un médecin ou par un système automatique basé sur l'intelligence artificielle [13].

1.3.2 Manifestations de l'infarctus du myocarde sur l'ECG et corrélation territoriale

L'électrocardiogramme (ECG) constitue l'examen de première intention pour la détection d'un infarctus du myocarde. Lorsqu'une partie du muscle cardiaque ne reçoit plus suffisamment d'oxygène à cause d'une obstruction d'une artère coronaire, l'activité électrique locale est perturbée. Cette perturbation se traduit par des modifications visibles de la forme des ondes et des segments du tracé ECG. L'identification de ces modifications permet d'orienter rapidement le diagnostic [12] [13].

Le signe le plus important concerne le segment ST. Dans les formes aiguës d'infarctus, on observe souvent un sus-décalage du segment ST, c'est-à-dire une élévation anormale de ce segment par rapport à la ligne de base. Cette élévation traduit une souffrance sévère et profonde du muscle cardiaque. Dans d'autres cas, notamment lors d'ischémie non transmurale, le segment ST peut être sous-décalé, ce qui indique également une anomalie de l'irrigation myocardique [13].

Electrocardiography




Figure 1-7 Principales modifications morphologiques du tracé ECG lors d'un infarctus. On observe le tracé normal (haut gauche), le sus-décalage du segment ST (haut droite), le sous-décalage de ST (bas gauche) et l'inversion de l'onde T signalant une ischémie (bas) [15].

L'onde T, qui correspond à la phase de récupération électrique des ventricules, peut aussi être modifiée. Elle peut devenir inversée, aplatie ou anormalement pointue. Ces changements traduisent une perturbation de la repolarisation ventriculaire dans la zone atteinte [12]. Avec l'évolution de la lésion, une onde Q pathologique peut apparaître dans le complexe QRS. Cette onde Q anormale correspond généralement à une zone de muscle nécrosé qui ne participe plus correctement à la conduction électrique. Elle est souvent associée à un infarctus déjà constitué [12]. Ces anomalies ne surviennent pas toujours simultanément. Leur présence dépend du stade d'évolution de l'infarctus et de l'étendue de la zone touchée. L'analyse du tracé ECG doit donc tenir compte à la fois de la forme des ondes et de leur distribution sur les différentes dérivations [13].

Corrélation territoriale selon les dérivations

L'ECG à 12 dérivations observe le cœur selon plusieurs angles. Chaque groupe de dérivations explore une zone particulière du ventricule gauche. Lors d'un infarctus du myocarde, les anomalies (sus-décalage ST, inversion de T, onde Q) apparaissent dans les dérivations qui "regardent" la région atteinte [16]. L'interprétation ne repose donc pas sur une seule dérivation, mais sur un groupe de dérivations voisines.

On distingue classiquement les correspondances suivantes :

- Les dérivations **DII, DIII et aVF** explorent la paroi inférieure du cœur ; leurs anomalies suggèrent un infarctus inférieur.
- Les dérivations **V1 à V3** explorent la région antéro-septale.
- Les dérivations **V3 et V4** sont liées à la paroi antérieure.
- Les dérivations **DI, aVL, V5 et V6** correspondent à la paroi latérale.

En pratique clinique, la présence d'anomalies concordantes dans au moins deux dérivations contiguës renforce fortement la probabilité diagnostique [17]. Cette organisation spatiale des dérivations est essentielle pour comprendre comment les méthodes d'analyse automatique d'images ECG peuvent apprendre à associer des motifs visuels à une localisation cardiaque précise.

1.3.3 Intérêt du diagnostic automatique de l'infarctus à partir des images ECG

L'interprétation de l'électrocardiogramme est une tâche médicale essentielle mais exigeante. Elle nécessite de l'expérience, de la concentration et du temps, car certaines anomalies peuvent être discrètes ou progressives. Dans le cas de l'infarctus du myocarde, un retard de diagnostic peut entraîner des conséquences graves. Il est donc important de disposer d'outils capables d'assister le personnel médical dans la détection rapide des signes anormaux sur les tracés ECG [12] [13].

Avec les progrès de l'intelligence artificielle, il est désormais possible de développer des systèmes automatiques capables d'analyser des images ECG. Les réseaux de neurones convolutifs ou convolution neural networks (CNN) sont particulièrement adaptés à cette tâche, car ils sont conçus pour reconnaître des formes et des motifs visuels complexes. Or, un tracé ECG est justement une représentation graphique contenant des motifs caractéristiques liés à l'état du muscle cardiaque.

L'analyse automatique présente plusieurs avantages : elle permet un traitement rapide d'un grand nombre d'examen, une réduction de la variabilité d'interprétation entre

observateurs, et un soutien à la décision clinique. Elle peut aussi être intégrée dans des systèmes de télémédecine ou des applications d'aide au diagnostic, notamment dans des contextes où l'expertise cardiologique n'est pas toujours disponible [13].

Dans le cadre de ce travail, l'objectif n'est pas de remplacer le médecin, mais de proposer un système d'aide basé sur l'apprentissage profond, capable d'identifier des motifs visuels associés à l'infarctus sur des images ECG prétraitées. Cette approche s'inscrit dans la continuité des recherches actuelles en diagnostic assisté par ordinateur.

1.4 Notions de Machine Learning et Deep Learning

L'intelligence artificielle (IA) occupe aujourd'hui une place essentielle dans le domaine biomédical, notamment dans l'analyse automatisée des signaux physiologiques tels que l'électrocardiogramme (ECG). Les progrès réalisés en apprentissage automatique (Machine Learning) et en apprentissage profond (Deep Learning) ont permis de développer des systèmes capables de reconnaître, classifier et prédire divers troubles cardiaques avec une grande précision.

1.4.1 Machine Learning

Le Machine Learning ou apprentissage automatique regroupe un ensemble de méthodes permettant à une machine d'apprendre à partir de données, sans être explicitement programmée pour une tâche donnée. Son principe consiste à extraire automatiquement des modèles ou des relations statistiques à partir d'exemples, afin de généraliser ces connaissances à de nouvelles données.

Les algorithmes les plus courants incluent la régression logistique, les *Support Vector Machines (SVM)*, les *k-Nearest Neighbors (k-NN)* ou encore les *Random Forests*. Ces approches sont souvent utilisées pour la classification, la régression ou la détection d'anomalies.

Dans le cadre de l'analyse ECG, les méthodes de Machine Learning reposent généralement sur l'extraction manuelle de caractéristiques pertinentes, telles que la durée des intervalles PR, QRS, QT, la fréquence cardiaque, ou encore l'énergie spectrale des signaux [11]. Ces caractéristiques sont ensuite introduites dans un classificateur pour distinguer les battements normaux des battements pathologiques. Toutefois, cette étape d'extraction manuelle reste dépendante de l'expertise humaine et peut limiter la performance globale du système.

1.4.2 Deep Learning

Le *Deep Learning* ou apprentissage profond constitue une branche avancée du Machine Learning basée sur l'utilisation de réseaux de neurones artificiels à plusieurs couches. Ces réseaux ont la capacité d'apprendre automatiquement des représentations hiérarchiques complexes des données brutes, sans intervention humaine dans la phase d'extraction des caractéristiques.




Figure 1-8 Comparaison entre les méthodes (a) traditionnelles et (b) basées sur le Deep Learning pour la classification des signaux ECG [20].

L'application d'une procédure mathématique appelée convolution, au moins une fois dans chacune de leurs couches, est la caractéristique distinctive qui donne son nom aux CNN. À l'instar de la réaction des neurones du cerveau humain face à un stimulus, cette activité de convolution a une fonction précise. Les CNN sont particulièrement adaptés aux tâches impliquant des structures de type grille, car ils sont très efficaces pour reconnaître les motifs et les caractéristiques des données d'entrée grâce à la convolution.




Figure 1-9 Opération de convolution [21]

L'apprentissage profond se distingue par sa capacité à traiter de grands volumes de données et à modéliser des relations non linéaires. Les principales architectures de Deep Learning utilisées dans le domaine médical comprennent les réseaux de neurones convolutifs (CNN), les réseaux récurrents (RNN, LSTM, GRU) et les architectures hybrides combinant ces modèles.

Dans l'analyse de signaux ECG, le Deep Learning a démontré une efficacité remarquable dans la reconnaissance automatique des battements cardiaques et la détection d'arythmies, surpassant les méthodes traditionnelles dans de nombreux travaux de recherche récents [10] [12].

1.4.3 Réseaux de Neurones Convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) constituent une classe spécialisée de réseaux de neurones artificiels, conçus spécifiquement pour traiter des structures d'entrée de type grille. Les données de séries temporelles, que l'on peut assimiler à une grille unidimensionnelle, ou les photographies, qui sont en réalité des grilles bidimensionnelles composées de pixels, sont des exemples de ces grilles de données. En substance, la couche d'entrée, une ou plusieurs couches cachées et la couche de sortie sont les trois éléments constitutifs de base des CNN et autres réseaux de neurones à propagation avant.




Figure 1-10 Architecture typique d'un réseau de neurones convolutif (CNN) [22].

Un CNN est composé de plusieurs types de couches :

- Les **couches de convolution**, qui extraient les caractéristiques locales à l'aide de filtres (ou noyaux) se déplaçant sur les données d'entrée ;
- Les **couches de pooling**, qui réduisent la dimensionnalité en conservant les informations les plus significatives ;

- Les **couches entièrement connectées**, qui interprètent les caractéristiques extraites et produisent la décision finale ;
- Les **fonctions d'activation** (telles que ReLU ou Softmax), qui introduisent la non-linéarité dans le modèle.

Les CNN ont démontré une grande efficacité dans la classification des pathologies cardiaques, notamment à partir de tracés ECG transformés en images. Ils permettent d'identifier automatiquement les motifs visuels complexes, tels que le sus-décalage du segment ST ou l'inversion de l'onde T, qui caractérisent les différents stades de l'infarctus du myocarde [24].

Les principales limites de cette approche résident dans la nécessité de disposer d'un grand volume de données annotées et dans la sensibilité potentielle du modèle aux artefacts ou au déséquilibre des classes [10]. Pour pallier ces difficultés, les chercheurs ont proposé des modèles hybrides, tels que les CNN-LSTM, ainsi que des techniques d'augmentation de données et de transfert d'apprentissage.

1.5 Détection automatique de l'Infarctus du Myocarde : État de l'art

La détection automatique de l'infarctus du myocarde (MI) constitue aujourd'hui un axe majeur de recherche en informatique biomédicale. Elle vise à assister le diagnostic clinique en réduisant la variabilité de l'interprétation humaine et en accélérant l'analyse des tracés électrocardiographiques [24]. L'évolution des approches dans ce domaine s'est faite progressivement, depuis les méthodes classiques d'apprentissage automatique fondées sur des caractéristiques extraites manuellement, jusqu'aux modèles d'apprentissage profond capables d'apprendre directement à partir des données brutes ou des images ECG [25].

1.5.1 Approches classiques d'apprentissage automatique

Les premières méthodes de détection automatique reposaient sur des algorithmes de Machine Learning supervisé. Ces approches nécessitaient une étape préalable d'extraction de caractéristiques à partir du signal ECG. Les paramètres les plus utilisés incluaient notamment le décalage du segment ST, la morphologie de l'onde Q, la polarité de l'onde T, ainsi que différentes mesures d'intervalles temporels [24].

Ces caractéristiques étaient ensuite introduites dans des classificateurs statistiques tels que les machines à vecteurs de support (SVM), les arbres de décision ou les forêts aléatoires (Random Forests). Bien que ces méthodes aient démontré une efficacité appréciable, leurs performances dépendaient fortement de la qualité du prétraitement, de la précision de la détection des points caractéristiques et de l'expertise utilisée pour définir les variables pertinentes. Cette dépendance limitait leur capacité de généralisation à des données hétérogènes ou bruitées [24].

1.5.2 Apprentissage profond et modèles convolutifs

L'introduction de l'apprentissage profond a profondément transformé la détection automatisée des pathologies cardiaques. Les réseaux de neurones convolutifs permettent d'apprendre automatiquement des représentations discriminantes à partir des signaux ou des images, sans nécessiter une extraction manuelle de caractéristiques [26].

Deux grandes stratégies sont observées dans les travaux récents :

1. **L'analyse du signal temporel** : Exploitant directement le signal ECG sous forme temporelle, à l'aide de modèles convolutifs unidimensionnels (**CNN 1D**) ou hybrides.
2. **L'analyse d'images ECG** : où les tracés sont traités comme des représentations visuelles 2D. Cette approche, qui utilise des architectures de vision par ordinateur, permet d'atteindre des précisions comparables, voire supérieures, aux experts dans la détection du STEMI [25].

Les approches basées sur l'image présentent un intérêt particulier lorsque les ECG sont disponibles sous forme de documents scannés ou photographiés. Elles permettent d'exploiter la structure visuelle globale du tracé, incluant la morphologie des ondes et la distribution spatiale des anomalies sur plusieurs dérivations.

1.5.3 Problème de robustesse et conditions réelles

Un défi important mis en évidence dans la littérature concerne la robustesse des modèles face aux données issues de conditions réelles [27]. Les ECG cliniques sont souvent affectés

par des artefacts physiques (plis du papier, taches), des bruits de numérisation ou des conditions de capture variables (photographies par smartphone) [28].

Si de nombreux modèles atteignent des performances quasi parfaites sur des bases de données "propres", leur efficacité chute significativement face à ces dégradations. Pour y remédier, des stratégies d'augmentation de données et de transfert d'apprentissage (*fine-tuning*) à partir de bases de données intégrant des artefacts réalistes sont désormais préconisées pour garantir une fiabilité clinique [27] [28].

Ces approches visent à améliorer la capacité de généralisation des réseaux de neurones et à rapprocher les conditions d'évaluation expérimentale des conditions d'utilisation clinique réelle. Cette problématique de robustesse constitue un enjeu central dans le développement de systèmes fiables d'aide au diagnostic automatisé.

1.6 Conclusion partielle

Ce chapitre a présenté les bases essentielles relatives au fonctionnement du cœur, au signal électrocardiographique et à la physiopathologie de l'infarctus du myocarde. Nous avons établi les critères diagnostiques visuels (segment ST, onde T) qui serviront de base à notre système. Nous avons également rappelé les notions fondamentales de Machine Learning et de Deep Learning, indispensables à la compréhension des architectures modernes comme les CNN. Ces éléments constituent le socle théorique sur lequel s'appuie la phase méthodologique de ce travail, consacrée à l'utilisation de la base de données PTB-XL et du modèle ConvNeXt.

Chapitre 2

Méthodologie et Mise en œuvre

2.1 Introduction partielle

Après avoir posé les bases théoriques et exploré l'état de l'art des CNN, ce chapitre détaille la démarche pratique adoptée pour répondre à notre problématique. Le défi majeur réside dans la capacité du modèle à maintenir une précision diagnostique élevée malgré les artefacts complexes inhérents aux ECG papier.

Nous exposons ici l'architecture méthodologique de notre solution, en commençant par la présentation du corpus de données issu de la base PTB-XL et du challenge PhysioNet 2024 [4]. Nous détaillons ensuite les processus de prétraitement, le choix du modèle ConvNeXt-Small ainsi que les stratégies d'entraînement. Enfin, nous présentons la conception détaillée du système, structurée autour de diagrammes UML, pour transformer ce modèle en un véritable outil d'aide à la décision médicale.

2.2 Matériel : Données et Corpus

2.2.1 Dataset PTB-XL : Présentation Générale et Annotations

Diagnostiques

Le jeu de données PTB-XL constitue la principale source utilisée dans ce travail. Il s'agit d'une base publique de grande envergure, disponible via PhysioNet, comprenant 21 837 enregistrements ECG cliniques de 10 secondes, issus de 18 885 patients. Chaque enregistrement inclut 12 dérivations standards, échantillonnées à 500 Hz, et annotées par des cardiologues expérimentés [29].

Le principal intérêt de PTB-XL réside dans la qualité clinique de ses annotations, organisées selon la hiérarchie diagnostique standardisée SCP-ECG. Ces annotations constituent une référence fiable pour l'entraînement et l'évaluation de modèles d'intelligence artificielle en cardiologie. Dans ce travail, les signaux ECG numériques originaux sont considérés comme la vérité terrain clinique (ground truth), garantissant la fiabilité des labels associés aux images utilisées pour l'apprentissage.

Les métadonnées du dataset, disponibles dans le fichier `ptb-xl_database.csv`, associent à chaque ECG :

- Un identifiant unique (`ecg_id`),

- Des informations démographiques (âge, sexe),
- Des paramètres d'acquisition,
- Un ensemble de codes diagnostiques SCP (`scp_codes`).

Chaque ECG peut comporter plusieurs codes SCP, reflétant la nature multi-label des pathologies cardiaques. Pour garantir une exploitation clinique cohérente, ces codes sont mappés vers des super-classes diagnostiques (ex. : NORM, MI, STTC, CD, HYP) à l'aide du fichier `scp_statements.csv`, validé par des experts médicaux [29].

Dans le cadre de cette étude, seule la super-classe diagnostique principale est retenue, afin de simplifier la classification tout en conservant une signification clinique claire.

2.2.2 Construction du Corpus : de la sélection clinique à l'image ECG

L'objectif de ce travail est de distinguer un tracé **Normal (NORM)** d'un **Infarctus du Myocarde (MI)**. Pour cela, nous avons adopté une approche orientée "vision par ordinateur". Plutôt que de traiter les signaux 1D bruts, nous utilisons les représentations graphiques issues du dataset *ptb-xl-ecg-image-gmc2024* [4]. Ce corpus transforme les enregistrements de PTB-XL en images PNG respectant la disposition standard des 12 dérivations, telle qu'un cardiologue les analyserait sur papier.

Le processus a d'abord consisté en une "purification" des données. Nous avons filtré les métadonnées pour ne retenir que les patients appartenant strictement à l'une de nos deux classes cibles, en excluant les pathologies croisées ou ambiguës. Une attention particulière a été portée à la qualité des fichiers : tout enregistrement dont l'image était manquante, corrompue ou incomplète a été écarté.

Pour stabiliser l'apprentissage, nous avons ensuite traité le déséquilibre naturel entre les cas sains (majoritaires) et les infarctus. Un **sous-échantillonnage aléatoire** a été appliqué pour aligner le nombre d'exemples NORM sur celui des MI, aboutissant à un dataset équilibré d'environ 4 700 images par classe. Cette étape est essentielle pour éviter que le modèle ne développe un biais statistique et ne prédise la "normalité" par simple facilité.

Enfin, pour garantir l'intégrité des résultats, le partitionnement des données a été réalisé par identifiant patient. Cette précaution élimine tout risque de *data leakage* : un même patient ne peut pas servir à l'entraînement et se retrouver ensuite dans le groupe de test. En isolant ainsi un groupe de patients pour le test de robustesse final, nous nous assurons que les performances reflètent une réelle capacité de généralisation médicale.

Transformation des données : du signal ECG brut vers le corpus d'images



Figure 2-1 Transformation des données : du signal ECG brut vers le corpus d'images

2.2.3 Corpus de robustesse : l'épreuve des données dégradées

En complément du corpus principal, nous avons constitué un second jeu de données pour tester les limites du modèle face à des conditions réelles. Ce corpus, issu du challenge de numérisation d'ECG papier [4], regroupe des dégradations visuelles variées : **scans de documents froissés, photographies mobiles floues, pertes de contraste ou reflets d'éclairage.**

L'intérêt de ce corpus est purement évaluatif. Ces images ne sont jamais présentées au modèle durant son apprentissage ou sa validation. Cette séparation stricte, détaillée dans le Tableau 2-1, fait office de « crash-test » : elle permet de vérifier si le réseau ConvNeXt sait faire abstraction du support physique pour se concentrer uniquement sur le tracé clinique.

Tableau 2-1 Composition du corpus de robustesse constitué d'images ECG dégradées (scans et photographies mobiles).

Catégorie	Classe 0 (Sains)	Classe 1 (Pathologiques)	Total
ECG Dégradés (Test de robustesse)	71	71	142
Statut d'entraînement	Exclu	Exclu	Sécurisé

Cette séparation garantit l'indépendance expérimentale entre les données d'apprentissage et les données utilisées ultérieurement pour l'étude de la robustesse du modèle.

2.2.4 Synthèse du dataset d'entraînement

Le dataset final est structuré de manière à associer chaque image (en basse résolution _lr-0.png pour optimiser les temps de calcul) à son label binaire. La répartition, présentée dans le Tableau 2-2, suit un découpage classique 80/10/10. L'équilibre parfait entre les classes 0 (NORM) et 1 (MI) garantit que les métriques de performance obtenues seront le reflet d'une véritable expertise de classification et non d'un hasard statistique lié à la majorité d'une classe.

Tableau 2-2 Répartition des échantillons du corpus d'apprentissage (PTB-XL) après filtrage binaire et équilibrage par sous-échantillonnage.

Ensemble de données	Classe 0 (Normal)	Classe 1 (Infarctus - MI)	Total
Entraînement (80%)	3 776	3 777	7 553
Validation (10%)	472	472	944
Test Standard (10%)	473	472	945
Total Global	4 721	4 721	9 442

2.3 Prétraitement des images ECG

Le passage des images PNG brutes vers le modèle ConvNeXt nécessite une préparation spécifique. L'objectif est de normaliser les fichiers tout en apprenant au modèle à ignorer les défauts visuels des photos. Nous avons utilisé la bibliothèque torchvision.transforms pour créer deux circuits de transformation distincts.

2.3.1 Pipeline d'entraînement

Pour l'entraînement, nous appliquons des transformations aléatoires afin de simuler les imperfections d'une capture manuelle :

- **Redimensionnement** : Les images sont fixées à 512×512 pixels. Ce format permet un traitement par lots (*batches*) efficace tout en conservant assez de détails pour distinguer les ondes P ou T.
- **Modifications géométriques** : Nous appliquons des rotations, des translations et des zooms limités à $\pm 5\%$. Ces valeurs sont volontairement basses : une déformation trop forte changerait l'interprétation clinique du tracé (par exemple, un segment ST artificiellement étiré).

- **Qualité d'image** : Nous varions la luminosité et le contraste pour reproduire les conditions de numérisation d'un hôpital. Un flou gaussien est aussi injecté de manière aléatoire pour forcer le modèle à reconnaître les ondes même quand la photo est légèrement mal réglée.
- **Normalisation** : Enfin, les images sont converties en tenseurs et normalisées selon les standards d'ImageNet (moyenne : 0.485, 0.456, 0.406) [30]. Cela permet d'utiliser efficacement les poids pré-entraînés du modèle ConvNeXt.

2.3.2 Pipeline de Validation et de test

Pour l'évaluation, nous supprimons tout l'aléatoire. Les images subissent uniquement le redimensionnement et la normalisation. Ce pipeline "fixe" assure que les performances mesurées en validation et sur le corpus de robustesse ne dépendent pas d'une transformation chanceuse, mais bien de la qualité intrinsèque du tracé.

2.4 Architecture du modèle de classification

L'objectif de cette étude est de développer un modèle capable de classifier automatiquement des images d'électrocardiogrammes en deux catégories diagnostiques : tracé normal (NORM) et infarctus du myocarde (MI). Pour répondre à cette problématique, une architecture de réseau de neurones convolutifs moderne, robuste et optimisée pour la vision par ordinateur a été retenue.

Le modèle est implémenté dans l'environnement PyTorch, qui offre une flexibilité élevée pour la définition, l'entraînement et l'évaluation de réseaux profonds.

2.4.1 Choix de l'architecture : ConvNeXt-Small

Le succès de la détection d'infarctus sur des photos d'ECG repose avant tout sur le choix du modèle. Nous avons sélectionné l'architecture **ConvNeXt-Small**, qui modernise les réseaux convolutifs classiques en y intégrant des principes issus des *Transformers* [30]. Contrairement aux modèles plus anciens comme ResNet ou VGG utilisés dans de précédents travaux [31], ConvNeXt utilise des noyaux de grande taille (7×7). Ce choix est important pour la cardiologie : il permet au réseau de capturer un complexe QRS ou un segment ST en une seule fois, facilitant la compréhension globale du signal là où des filtres plus petits (3×3) fragmenteraient l'information.

Cette architecture utilise également une structure en **Inverted Bottleneck** et des convolutions *depthwise*. Ce mécanisme permet de traiter plus d'informations tout en

limitant le nombre de paramètres, ce qui évite au modèle de "sur-apprendre" le bruit de fond des images papier. L'organisation détaillée de ces blocs, illustrée en Figure 2-2, montre comment le réseau réduit progressivement la résolution pour extraire des caractéristiques de plus en plus abstraites [32].




Figure 2-2 Architecture détaillée du modèle ConvNeXt. (a) Structure d'un bloc élémentaire intégrant une convolution depthwise de taille 7×7 , suivie d'une Layer Normalization et d'une expansion de canaux de type Inverted Bottleneck. (b) Organisation globale des étapes de réduction de résolution (*Downsampling*) et des blocs résiduels composant le réseau [32].

Robustesse et adaptation au diagnostic

Pour affronter les dégradations visuelles (flou, reflets, perspective), nous avons opté pour la version "Small" pré-entraînée sur **ImageNet-22k** [33]. La richesse des filtres appris sur ce vaste corpus permet au modèle de rester efficace même face au "Domain Gap" [32], c'est-à-dire l'écart visuel entre un ECG numérique parfait et une photographie mobile bruitée. Cette stabilité est renforcée par l'usage de la **Layer Normalization**, qui rend le modèle beaucoup moins sensible aux variations d'éclairage que la normalisation classique par batch.

Enfin, nous avons adapté la tête du modèle pour notre classification binaire (Sain vs Infarctus). Nous avons fixé une résolution d'entrée de 512×512 pixels pour ne pas perdre la finesse des ondes P et T, souvent invisibles sur des résolutions plus faibles. Pour forcer le modèle à la prudence, nous avons imposé un **Dropout élevé (0.6)** : cela oblige le réseau

à apprendre une représentation globale du tracé plutôt que de se focaliser sur quelques pixels isolés. Ce choix de la version "Small" (50 millions de paramètres) offre selon nous le meilleur compromis entre puissance d'analyse et rapidité de diagnostic, tout en évitant que le modèle ne mémorise des défauts spécifiques au papier plutôt que la pathologie elle-même.

2.5 Protocole d'entraînement du modèle

L'entraînement du modèle repose sur une séparation stricte des données par patient, comme défini précédemment. L'ensemble d'entraînement sert à l'ajustement des poids du réseau, celui de validation au réglage des hyperparamètres, et l'ensemble de test est conservé exclusivement pour l'évaluation finale.

2.5.1 Configuration d'optimisation et Fonction de Perte

Pour piloter l'apprentissage de ConvNeXt-Small, nous avons sélectionné l'optimiseur **AdamW**. Contrairement à l'algorithme Adam classique, AdamW gère mieux la décroissance des poids (*weight decay*), ce qui améliore la généralisation du modèle [33]. Ce choix est particulièrement adapté aux images d'ECG papier : il aide le réseau à ignorer les détails inutiles, comme la texture du papier ou le bruit de fond, pour se concentrer sur le tracé.

Concernant la fonction de perte, Dans la configuration finale du modèle, nous introduisons la **Focal Loss** afin d'améliorer l'apprentissage sur les exemples difficiles. Les premières expérimentations utilisent toutefois la fonction de perte standard **BCEWithLogitsLoss**, qui sert de modèle de référence (baseline) [34]. Dans notre dataset, les exemples "faciles" (tracés très clairs) risquent de dominer l'apprentissage au détriment des cas complexes. La Focal Loss règle ce problème grâce à un paramètre γ (fixé à 2.0) qui réduit l'importance des exemples bien classés. Cela force le modèle à se focaliser sur les signes subtils de l'infarctus, comme une légère élévation du segment ST ou une inversion de l'onde T.

La perte est définie par :

$$FL(pt) = -\alpha_t(1 - pt)^\gamma \log(pt) \quad (1)$$

Ici, pt représente la probabilité prédite par le modèle pour la classe réelle (ground truth).




Figure 2-3 Comportement de la Focal Loss en fonction de la probabilité de la classe réelle (p_t) [34].

2.5.2 Stratégie de suivi et précision mixte

Afin d'éviter le surapprentissage (*overfitting*), nous utilisons un mécanisme d'**arrêt anticipé** (*Early Stopping*). L'entraînement s'interrompt automatiquement si la performance sur l'ensemble de validation ne progresse plus. À la fin, seul le meilleur état du modèle (le plus généralisable) est sauvegardé.

Pour accélérer ce processus, nous avons utilisé la **précision mixte** principalement pour accélérer l'entraînement. Sur un modèle profond comme ConvNeXt-Small avec des images en 512x512, le gain de temps est important et permet de tester plus d'hypothèses rapidement. Pour ne pas perdre en précision, nous avons utilisé un *GradScaler* : cet outil stabilise les calculs mathématiques (gradients) lorsqu'on passe en demi-précision (FP16), évitant ainsi que le modèle ne diverge.

2.5.3 Seuil de décision et sécurité clinique

Dans un problème de classification binaire utilisant une fonction d'activation sigmoïde, le modèle produit pour chaque image ECG une probabilité $p \in [0,1]$ d'appartenance à la classe positive (Infarctus du Myocarde –MI).

Par défaut, une probabilité supérieure ou égale à 0,5 est généralement interprétée comme une prédiction positive. Cependant, dans un contexte de diagnostic médical d'urgence, les conséquences cliniques d'un faux négatif (un infarctus non détecté) sont bien plus graves que celles d'un faux positif (une alerte injustifiée). Pour aligner les décisions du modèle sur ces impératifs de sécurité patient, nous avons opté pour une optimisation du seuil basée sur l'**Indice de Youden Pondéré** [32].

L'indice de Youden classique accorde un poids équivalent à la sensibilité et à la spécificité. Dans ce travail, pour privilégier la capacité de détection des pathologies, nous introduisons

un facteur de pondération ω appliqué à la sensibilité (TPR). Le seuil optimal retenu est celui qui maximise la fonction suivante sur l'ensemble de validation :

$$J_{\omega} = (\omega \times \text{Sensibilité}) + \text{Spécificité} - 1 \quad (2)$$

Où :

- ω est le coefficient de pondération (fixé à 2.0 dans notre protocole) permettant d'accorder plus d'importance à la détection des cas pathologiques ;
- **Sensibilité (TPR)** représente le taux de vrais positifs (capacité à détecter l'infarctus) ;
- **Spécificité (TNR)** représente le taux de vrais négatifs (capacité à identifier les patients sains).

En doublant le poids de la sensibilité, nous déplaçons le curseur du modèle pour garantir une détection maximale des pathologies. Ce seuil est calculé sur l'ensemble de validation juste après l'entraînement, puis figé pour les tests finaux. Cette méthode assure que l'outil se comporte de manière réaliste face à un clinicien qui cherche avant tout à ne manquer aucun cas critique [31].

2.6 Méthodes d'évaluation des performances

L'efficacité du modèle est mesurée exclusivement sur des données qu'il n'a jamais rencontrées : l'ensemble de test standard (numérique) et le corpus de robustesse (photos dégradées). Pour un diagnostic médical, l'exactitude globale (*accuracy*) ne suffit pas ; nous privilégions des indicateurs qui sanctionnent sévèrement les erreurs critiques, notamment les faux négatifs.

2.6.1 Analyse quantitative : Matrice de confusion et métriques dérivées

La matrice de confusion est notre outil central. Elle permet de visualiser précisément comment le modèle répartit ses prédictions selon quatre catégories :

- **Vrais Positifs (VP)** : Infarctus correctement détectés.
- **Vrais Négatifs (VN)** : ECG normaux correctement identifiés.
- **Faux Positifs (FP)** : Alertes injustifiées sur des patients sains.
- **Faux Négatifs (FN)** : Infarctus non détectés (l'erreur la plus critique).

À partir de cette répartition, nous calculons les indicateurs clés pour valider l'usage clinique du modèle :

- **Sensibilité (Rappel) :** C'est notre priorité. Elle mesure la capacité du réseau à ne manquer aucun infarctus. Une sensibilité élevée réduit drastiquement les faux négatifs, garantissant une meilleure sécurité pour le patient.
- **Spécificité :** Elle évalue l'aptitude à identifier les patients sains. Une spécificité solide limite les fausses alertes qui pourraient surcharger inutilement les services d'urgence.
- **Score F1 :** Il représente la moyenne harmonique entre la précision et la sensibilité. C'est l'indicateur de performance globale : il confirme que le modèle ne réussit pas par hasard, mais qu'il maintient un équilibre fiable entre la détection et la justesse du diagnostic, sans sacrifier l'une pour l'autre.

$$F1 = 2 \times \frac{\text{Précision} \times \text{Sensibilité}}{\text{Précision} + \text{Sensibilité}} \quad (3)$$

Avec :

$$\text{Précision} = \frac{VP}{VP + FP} \quad (4)$$

Cette métrique est particulièrement pertinente pour les problèmes de classification médicale binaire.

2.6.2 Courbe ROC et aire sous la courbe

La courbe ROC représente l'évolution du taux de vrais positifs en fonction du taux de faux positifs pour différents seuils de décision. Elle permet d'analyser le comportement du modèle indépendamment d'un seuil fixe.

L'aire sous la courbe ROC (AUC) constitue un indicateur synthétique de la capacité de séparation entre les deux classes. Plus cette aire est élevée, meilleure est la capacité discriminante du modèle.

Cette analyse est utilisée pour sélectionner un seuil de décision cliniquement adapté.

2.7 Interprétabilité du modèle par cartes d'activation

En médecine, la performance brute d'un algorithme ne suffit pas à garantir son adoption. Pour qu'un système d'IA soit crédible, le clinicien doit pouvoir visualiser les raisons qui ont mené à un diagnostic. Pour lever l'opacité du modèle ConvNeXt, nous avons intégré la méthode **Grad-CAM** (*Gradient-weighted Class Activation Mapping*).

2.7.1 Fonctionnement technique

Le principe du Grad-CAM consiste à utiliser les gradients de la classe prédite circulant dans la dernière couche du réseau. En pondérant les cartes de caractéristiques par ces gradients,

nous générons une **carte de chaleur** (*heatmap*) qui met en évidence les pixels ayant le plus influencé la décision. Cette carte est ensuite superposée à l'image originale de l'ECG pour une lecture immédiate.

2.7.2 Validation de la cohérence clinique

Appliquées aux images d'ECG, ces cartes d'activation permettent de vérifier si le modèle "raisonne" correctement. Nous cherchons à confirmer qu'il se focalise sur des marqueurs physiologiques tels que :

- Le **segment ST** (pour détecter une élévation ou une dépression),
- Le **complexe QRS** ou l'**onde T** (anomalies de repolarisation).

Cette étape est fondamentale pour s'assurer que l'IA ne fonde pas son jugement sur des artefacts non pertinents, comme la grille du papier, des reflets ou le cadrage de la photo.

Bien que ces visualisations ne constituent pas une preuve causale absolue, elles servent de garde-fou. Elles transforment l'IA d'un simple prédicteur en un véritable outil d'aide à la décision, capable de pointer du doigt l'anomalie pour le cardiologue, renforçant ainsi la confiance dans le diagnostic final.

2.8 Évaluation de la robustesse et de la généralisation

La dernière étape de notre méthodologie consiste en un « crash-test » sur le corpus d'images dégradées. Le protocole est strictement identique à celui du test standard, ce qui nous permet une comparaison directe des performances.

Nous analysons ici deux facteurs :

1. **La stabilité des métriques** : Le modèle conserve-t-il une sensibilité acceptable sur une photo floue ?
2. **La cohérence visuelle** : Les cartes Grad-CAM montrent-elles que le modèle parvient toujours à "lire" les ondes malgré le bruit visuel ?

Cette analyse comparative est ce qui détermine la viabilité réelle du projet dans un contexte d'utilisation mobile, hors des conditions contrôlées du laboratoire.

2.9 Conception du système d'aide au diagnostic ECG

2.9.1 Objectif du système

L'objectif du système proposé est de transformer le modèle de classification des images ECG, développé et validé expérimentalement dans les sections précédentes, en un outil opérationnel d'aide à la décision clinique. Il s'agit de concevoir une architecture logicielle

capable d'exploiter automatiquement un cliché d'électrocardiogramme afin de fournir une prédiction assistée concernant la présence ou l'absence d'un infarctus du myocarde (MI). Le système vise principalement à assister le personnel médical dans des contextes où l'expertise cardiologique spécialisée n'est pas immédiatement disponible. Dans certaines structures sanitaires à ressources limitées, un médecin peut disposer uniquement d'un tracé ECG imprimé ou photographié. Le système proposé cherche ainsi à fournir une analyse automatisée, rapide et interprétable, servant de support à la décision médicale sans se substituer au jugement clinique final.

Plus spécifiquement, les objectifs fonctionnels du système sont :

- **La prise en charge** d'images ECG (numériques, scannées ou photographiées) via une interface sécurisée.
- **L'automatisation du pipeline** de prétraitement et d'inférence par le modèle **ConvNeXt-Small**.
- **La détermination du diagnostic assisté** par l'application du seuil de décision optimisé (0.3946).
- **La génération d'explications visuelles** de type Grad-CAM pour localiser les zones d'intérêt clinique sur le tracé.
- **L'archivage et la traçabilité** des résultats pour permettre un suivi historique des dossiers patients.

L'approche retenue s'inscrit dans une logique d'intelligence artificielle explicable (XAI). L'intégration du mécanisme d'interprétabilité vise à renforcer la confiance du praticien en rendant transparent le raisonnement algorithmique. La section suivante détaille la modélisation de cette solution à travers les différents diagrammes de conception.

2.9.2 Architecture fonctionnelle et logicielle

L'architecture du système **CardioVision-MI** est conçue selon une organisation modulaire et découplée. Cette structuration permet de séparer les responsabilités entre l'interaction utilisateur, le traitement intensif des données et la persistance des résultats.

Le système s'articule autour de quatre modules fonctionnels intégrés dans une architecture **Client-Serveur** :

1. Interface Utilisateur (Module Frontend - Next.js)

L'interface constitue le point d'entrée sécurisé du système. Développée avec **Next.js**, elle assure :

- La prise en charge des clichés ECG (numériques ou photographiés).
- La visualisation dynamique des résultats et de la probabilité prédite.
- Le rendu de la carte d'activation Grad-CAM superposée à l'image originale.
- L'exportation des rapports de diagnostic.

2. Module de Prétraitement et de Contrôle

Ce module, intégré au backend FastAPI, prépare les données avant l'analyse. Il garantit la cohérence des prédictions en appliquant strictement le pipeline méthodologique :

- Redimensionnement des images au format 512×512 pixels.
- Normalisation des intensités selon les standards du modèle (ImageNet).
- Conversion des fichiers image en tenseurs compatibles avec PyTorch.

3. Module d'Inférence (Moteur IA - ConvNeXt)

Ce module encapsule le modèle **ConvNeXt-Small** préalablement entraîné. Fonctionnant exclusivement en mode inférence pour optimiser la rapidité de réponse, il est responsable de la propagation avant (*forward pass*) et du calcul du score de probabilité brut.

4. Module de Décision et d'Explicabilité

Ce module assure la traduction de la sortie mathématique en information clinique :

- **Logique de décision** : Application du seuil optimal (issu de l'indice de Youden) pour la classification binaire (NORM vs MI).
- **Génération Grad-CAM** : Calcul des cartes de chaleur mettant en évidence les segments de l'ECG (ondes P, complexes QRS, segments ST) ayant le plus contribué au diagnostic.
- **Persistance** : Enregistrement automatique des métadonnées dans la base de données **PostgreSQL** pour garantir la traçabilité.

2.9.3 Diagramme des cas d'utilisation

Présentation des acteurs

L'identification des acteurs permet de définir les frontières du système CardioVision-MI et les responsabilités associées. Nous distinguons deux acteurs principaux :

- **Le Médecin** : Acteur central dont l'objectif est d'exploiter le moteur d'IA pour obtenir une aide au diagnostic. Il gère les dossiers patients et lance les analyses ECG.
- **L'Administrateur** : Responsable technique chargé de la gestion des comptes et de la maintenance opérationnelle du système.

Ces deux acteurs héritent d'une classe de base Utilisateur, ce qui leur confère des attributs communs comme l'identifiant, l'email et le mot de passe haché.

Présentation du diagramme de cas d'utilisation

Le diagramme Figure 2-4 formalise les interactions fonctionnelles au sein du système. Pour garantir la clarté visuelle du schéma, les relations de dépendance vers le module de sécurité ne sont pas représentées graphiquement. Cependant, l'ensemble des fonctionnalités du système CardioVision-MI nécessite une authentification préalable via un mécanisme sécurisé basé sur JWT. Aucun cas d'utilisation métier (analyse ECG, gestion patients, export PDF, etc.) ne peut être exécuté sans une session valide et active.

Diagramme de cas d'utilisation du système CardioVision-MI




Figure 2-4 Diagramme de cas d'utilisation du système

Tableau 2-3 Documentation du cas d'utilisation principal : Lancer Analyse ECG

CU : Lancer Analyse ECG
ID : 1
Description brève : Permet au médecin d'obtenir un diagnostic automatique et une heatmap d'explicabilité à partir d'un cliché ECG.
Acteur primaire : Médecin
Préconditions : Le médecin doit être authentifié et avoir sélectionné un patient.
Enchaînement principal 1. Le cas d'utilisation démarre lorsque le médecin clique sur "Lancer analyse ECG". 2. Le système présente un formulaire de téléversement pour l'image (PNG/JPG). 3. Dès validation, le système active le Traitement IA : • Prétraitement de l'image (redimensionnement et normalisation). • Inférence par le modèle ConvNeXt-Small. • Application du seuil de décision et génération de la heatmap Grad-CAM. • Le système affiche les résultats et enregistre l'entité AnalysisResult en base de données.
Postconditions : Persistance du diagnostic lié au patient et mise à jour de l'historique clinique.
Extension : Possibilité de générer un rapport PDF à partir des résultats affichés.

2.9.4 Diagramme de classes

Le diagramme de classe constitue la modélisation statique du système, définissant la structure des données et les relations logiques entre les entités. Cette architecture repose sur un mécanisme de généralisation où la classe User fait office de socle commun pour la gestion de l'authentification. L'aspect clinique est structuré autour de la classe Patient, dont les données (nom, téléphone) sont chiffrées pour garantir la confidentialité médicale. L'élément central du système est la classe AnalysisResult ; elle fait office de passerelle entre le monde logiciel et le modèle d'apprentissage profond en encapsulant non seulement le score de probabilité et la décision binaire, mais également les paramètres d'explicabilité comme le chemin vers la heatmap Grad-CAM et le seuil de décision utilisé. Cette

conception garantit une traçabilité totale : chaque diagnostic est lié de manière immuable à une image source, un patient et le médecin prescripteur.




Figure 2-5 Diagramme de classes du système

2.9.5 Diagramme d'activité globale

Le diagramme d'activité globale modélise la dynamique du système et l'enchaînement des processus, de l'accès sécurisé à la restitution des résultats. Il met en lumière la séparation des flux entre la gestion administrative et le parcours clinique. Ce dernier est structuré autour d'un pipeline séquentiel où le traitement par l'intelligence artificielle est encapsulé dans une partition dédiée. On y observe la transition critique entre la réception du cliché brut et la génération synchronisée du diagnostic binaire et de la carte d'explicabilité. Ce flux garantit que l'utilisateur ne reçoit l'information décisionnelle qu'après la validation de toutes les étapes de calcul et de persistance des données.




Figure 2-6 Diagramme d'activité globale du système

2.10 Conclusion partielle

En somme, ce chapitre a permis de définir rigoureusement le cadre méthodologique de notre étude, allant de la sélection du modèle ConvNeXt-Small à la conception d'une architecture logicielle modulaire. L'intégration des principes d'explicabilité (XAI) et d'une structure logicielle robuste garantit que le système CardioVision-MI répond aux exigences de fiabilité et de traçabilité du milieu médical. Sur la base de cette conception, le chapitre suivant sera consacré à l'implémentation technique, au choix des environnements de développement et à la présentation des résultats obtenus lors des tests applicatifs.

Chapitre 3

Expérimentations, Analyse des Résultats et Discussion

3.1 Introduction partielle

Ce chapitre présente les expérimentations et l'analyse des résultats obtenus par le système CardioVision-MI. L'objectif n'est pas seulement d'évaluer la performance brute du modèle ConvNeXt, mais également d'examiner sa fiabilité dans des conditions proches de la pratique clinique.

En effet, les électrocardiogrammes peuvent être scannés, photographiés ou altérés par différents artefacts visuels liés au support physique. Ces variations peuvent affecter la qualité des images et représenter un défi pour les systèmes d'analyse automatisée.

Conformément aux objectifs de cette recherche, ce chapitre suit une démarche expérimentale en trois étapes : l'évaluation d'un modèle de référence (baseline), l'analyse de sa robustesse face à des images ECG dégradées, puis l'optimisation du modèle par l'introduction de techniques telles que la data augmentation et la Focal Loss.

3.2 Protocole Expérimental

3.2.1 Configuration matérielle

Les expérimentations ont été menées sur l'environnement Kaggle Notebooks, en utilisant une accélération matérielle composée de deux GPU NVIDIA Tesla T4. L'architecture ConvNeXt (variante *small*) a été instanciée via la bibliothèque `timm` et entraînée sous PyTorch. Afin d'assurer la reproductibilité des résultats, nous avons fixé la graine aléatoire à `seed = 32` et configuré `cuda` en mode déterministe. Enfin, pour optimiser la consommation de mémoire vidéo (VRAM) et accélérer les cycles d'entraînement, la précision mixte (AMP) a été implémentée via `torch.amp.GradScaler`.

3.2.2 Paramètres finaux du modèle baseline

L'architecture retenue pour l'expérience de référence (*baseline*) est le modèle ConvNeXt Small (`convnext_small.fb_in22k_ft_in1k`). Ce modèle a bénéficié d'un pré-entraînement massif sur ImageNet-22k avant d'être affiné sur ImageNet-1k, offrant ainsi une extraction de caractéristiques visuelles de haute précision pour l'analyse des signaux ECG complexes.

Le Tableau 3-1 synthétise les hyperparamètres et la configuration technique utilisés pour l'entraînement :

Tableau 3-1 Hyperparamètres et configuration technique du modèle baseline

Catégorie	Paramètre	Valeur / Configuration
Architecture	Modèle	ConvNeXt Small
	Poids pré-entraînés	<i>ImageNet</i> – 22k → 1k
Entrée	Résolution d'image	512 × 512 pixels
	Normalisation	Statistiques ImageNet (μ, σ)
Optimisation	Optimiseur	AdamW
	Taux d'apprentissage (LR)	3×10^{-5}
	Décomposition du poids	0.1
	Fonction de perte	BCEWithLogitsLoss
Régularisation	Dropout	0.6
	Early Stopping	Patience de 7 époques
Entraînement	Taille de lot (<i>Batch</i>)	16
	Époques maximales	25
	Précision numérique	<i>Mixed Precision</i> (AMP)

Pour assurer la cohérence avec les poids pré-entraînés, les images sont normalisées selon les standards d'ImageNet :

- Moyenne (μ) : [0.485, 0.456, 0.406]
- Écart-type (σ) : [0.229, 0.224, 0.225]

Le choix d'un Dropout élevé (0.6) constitue une mesure de régularisation stricte. Dans le contexte de la détection d'infarctus sur des images bruitées (scans, photos), cette configuration force le réseau à apprendre des motifs globaux de l'onde ECG plutôt que de se focaliser sur des artefacts spécifiques à la numérisation (grains de papier, plis, ombres). Le meilleur modèle est sélectionné sur la base de la perte minimale observée sur l'ensemble de validation, garantissant ainsi une capacité de généralisation optimale avant l'évaluation finale.

3.2.3 Scénarios expérimentaux

Afin d'évaluer l'impact des différentes stratégies d'apprentissage sur la performance diagnostique du modèle, nous avons mis en place un protocole de tests comparatifs. Cette approche vise à analyser l'effet progressif des techniques d'amélioration introduites au cours de l'étude.

Trois configurations expérimentales ont été définies.

- **Scénario 1**

Baseline : ce scénario constitue le point de référence de l'étude. Le modèle ConvNeXt-Small est entraîné sur les images ECG originales en utilisant la fonction de perte standard BCEWithLogitsLoss, sans aucune augmentation de données.

- **Scénario 2**

Baseline + Data Augmentation : ce scénario introduit le pipeline d'augmentation des données décrit précédemment (rotations légères, flou gaussien et ajustements de contraste). Ces transformations visent à simuler différentes dégradations visuelles susceptibles d'apparaître lors de la numérisation ou de la photographie d'ECG papier.

- **Scénario 3**

Baseline + Data Augmentation + Focal Loss : cette configuration correspond au modèle final. Elle combine la data augmentation avec l'utilisation de la Focal Loss, afin d'améliorer l'apprentissage sur les exemples difficiles et de renforcer la stabilité décisionnelle du modèle.

Cette démarche progressive permet d'évaluer l'apport de chaque amélioration et d'identifier la configuration offrant le meilleur compromis entre performance diagnostique et robustesse face aux variations de qualité d'image.

3.3 Résultats du modèle Baseline

3.3.1 Performances globales sur le jeu de test interne

Afin d'établir une référence de performance, le modèle ConvNeXt-Small a été entraîné sur les images ECG originales en utilisant la fonction de perte standard BCEWithLogitsLoss, sans augmentation de données. Cette configuration constitue le modèle baseline de notre étude.

Les performances ont été évaluées sur un jeu de test indépendant. Conformément au protocole expérimental, les prédictions sont analysées à deux niveaux :

- Au seuil par défaut (0,5)
- Au seuil optimisé à l'aide de l'indice de Youden pondéré, afin de privilégier la sensibilité diagnostique et de réduire le risque de faux négatifs.

Le Tableau 3-2 présente les principales métriques obtenues.

Tableau 3-2 Performances du modèle Baseline sur le jeu de test

Configuration	Seuil	Acc.	Sens. (Recall)	Spec.	F1-Score	AUC
Baseline (BCE)	0.50	0,921	0,935	0,907	0,922	0,9787
	0.18	0,892	0,953	0,830	0,898	0,9787

Les résultats montrent que le modèle baseline atteint une accuracy de 92,1 % sur le jeu de test standard, avec une AUC de 0.9787, indiquant une excellente capacité de discrimination entre les classes MI (Myocardie) et NORM (Normal).

L'optimisation du seuil décisionnel entraîne une augmentation de la sensibilité (0.935 → 0.953), ce qui permet de réduire le risque de faux négatifs. Cette amélioration s'accompagne toutefois d'une diminution de la spécificité (0.907 → 0.830), traduisant un compromis classique entre détection des cas pathologiques et exclusion des sujets sains.

Ces résultats confirment que le modèle baseline possède déjà une capacité de classification élevée sur des images ECG de bonne qualité.




Figure 3-1 Matrice de confusion et Courbe ROC du modèle Baseline

La figure présente à la fois la matrice de confusion (à gauche) et la courbe ROC (à droite).

La matrice de confusion montre que le modèle détecte correctement la majorité des cas MI (451 vrais positifs) avec un faible nombre de faux négatifs (22 cas), ce qui traduit une sensibilité élevée. En revanche, le nombre de faux positifs (80 cas) indique une diminution de la spécificité, due à l'abaissement du seuil décisionnel.

La courbe ROC met en évidence une excellente capacité de discrimination du modèle, avec une AUC de 0.9787. La courbe, largement au-dessus de la diagonale aléatoire, confirme que le modèle distingue efficacement les classes MI et NORM indépendamment du seuil.

3.3.2 Analyse qualitative de l'attention du modèle

Au-delà des métriques globales, il est important d'examiner les régions de l'image utilisées par le modèle pour prendre sa décision. Pour cela, une analyse d'interprétabilité basée sur Grad-CAM a été réalisée.

Les cartes d'activation obtenues suggèrent que le modèle concentre majoritairement son attention sur les structures physiologiquement pertinentes du tracé ECG, notamment :

- Les complexes QRS
- Les segments ST
- Certaines zones de transition entre les dérivations

Ces observations indiquent que le réseau exploite des caractéristiques morphologiques cohérentes avec l'interprétation clinique des électrocardiogrammes.




Figure 3-2 Visualisation Grad-CAM du modèle Baseline

3.3.3 Limites observées avec le modèle Baseline

Malgré ses bonnes performances globales, l'analyse des résultats met en évidence certaines limites du modèle baseline. Tout d'abord, l'obtention d'une sensibilité élevée nécessite un abaissement important du seuil décisionnel (0.18). Cette dépendance à un ajustement du seuil suggère que la distribution des probabilités prédictives reste relativement compressée autour de la frontière de décision.

Par ailleurs, l'analyse qualitative de certains cas observés dans le jeu de test suggère que la confiance prédictive du modèle peut diminuer en présence de dégradations visuelles importantes, telles que le flou de numérisation, les variations d'éclairage, les artefacts de capture photographique ou les altérations du support papier.

Dans ces situations, la probabilité prédite peut rester proche du seuil décisionnel malgré la présence d'un infarctus confirmé.

Ces observations suggèrent que le modèle baseline, entraîné uniquement sur des images ECG de haute qualité, pourrait présenter une sensibilité aux variations visuelles rencontrées dans des conditions réelles d'acquisition.




Figure 3-3 Performance du modèle selon le type de dégradation des images ECG.

Cette limitation motive l'introduction de stratégies d'apprentissage visant à améliorer la robustesse du modèle face aux dégradations des supports physiques, notamment à travers l'utilisation de techniques d'augmentation de données.

3.3.4 Analyse qualitative via Grad-CAM

Afin de mieux comprendre l'origine des difficultés rencontrées par le modèle dans certaines situations, une analyse qualitative basée sur Grad-CAM a été réalisée.

Les cartes d'activation suggèrent que, dans la majorité des cas, le modèle continue de se concentrer sur les structures principales du tracé ECG, notamment les complexes QRS et les segments ST.

Cependant, lorsque les dégradations visuelles deviennent importantes, une dispersion partielle de l'attention du modèle peut être observée. Certaines zones périphériques présentant un contraste élevé (ombres, artefacts d'impression, zones tachées) peuvent alors attirer une partie de l'activation du réseau.

Cette observation suggère que le modèle baseline peut être influencé par certaines caractéristiques visuelles non physiologiques lorsque la qualité de l'image se dégrade.




Figure 3-4 Grad-CAM sur ECG fortement dégradé

3.3.5 Discussion : limites du modèle baseline

L'ensemble de ces observations met en évidence une limite importante du modèle baseline : sa dépendance à des conditions d'acquisition relativement propres.

Bien que ses performances soient élevées sur le jeu de test standard, l'analyse qualitative et quantitative suggère que la stabilité décisionnelle peut diminuer lorsque les images présentent des altérations visuelles importantes.

Dans un contexte clinique réel, où les électrocardiogrammes peuvent être numérisés ou photographiés dans des conditions variables, cette sensibilité aux dégradations constitue un risque potentiel pour la fiabilité du système.

Ces résultats motivent l'introduction de stratégies d'apprentissage visant à améliorer la robustesse du modèle face aux variations visuelles, notamment à travers l'utilisation de techniques d'augmentation de données simulant ces conditions dégradées.

3.4 Optimisation du modèle

Dans cette section, nous présentons les différentes stratégies mises en œuvre pour améliorer les performances du modèle. À partir du modèle baseline, plusieurs approches ont été explorées, notamment la data augmentation et l'utilisation de la Focal Loss. Leur impact est analysé à travers l'étude de la convergence de l'entraînement et la comparaison des performances obtenues.

Analyse de la convergence de l'entraînement


L'évolution de la fonction de perte (Loss) a été analysée afin d'évaluer la dynamique d'apprentissage du modèle (Figure 3-5). La Loss représente l'erreur de prédiction : plus elle est faible, plus le modèle est performant.

La Figure 3-5 illustre les courbes de perte pour les trois configurations étudiées : le modèle baseline, le modèle avec data augmentation, et le modèle final intégrant la Focal Loss.


Dans le cas du modèle baseline (a), on observe une diminution initiale de la perte, suivie d'une augmentation de la perte de validation à partir de l'époque 3, ce qui indique un surapprentissage précoce. L'introduction de la data augmentation (b) permet de stabiliser l'apprentissage en réduisant l'écart entre les courbes d'entraînement et de validation.

Le modèle final (c) présente une convergence globalement stable, avec des courbes proches et une tendance décroissante. De légères fluctuations sont observées au niveau de la perte de validation ; celles-ci sont normales et s'expliquent par l'utilisation de la Focal Loss, qui met davantage l'accent sur les exemples difficiles, ainsi que par la variabilité introduite par la data augmentation. Malgré ces variations, la stabilité globale du modèle est maintenue, traduisant une meilleure capacité de généralisation.

Par ailleurs, la Figure 3-6 présente les matrices de confusion associées à chaque configuration. Elles permettent d'évaluer les performances de classification du modèle en distinguant les prédictions correctes et les erreurs, notamment entre les classes normales et pathologiques.




(a) Baseline




(b) Baseline + Augmentation

Figure 3-5 Évolution de la perte d'entraînement et de validation au cours des époques pour les trois modèles



(b) Baseline



(b) Baseline + Augmentation

Figure 3-6 Matrices de confusion au seuil optimal pour l'évaluation du diagnostic

Le modèle baseline (a) présente un nombre élevé de Faux Positifs (80 cas), traduisant une tendance à surestimer les pathologies. L'ajout de la data augmentation (b) réduit ces erreurs (67 cas), mais entraîne une légère augmentation des Faux Négatifs (26 cas).

Le modèle final (c), intégrant la Focal Loss, offre le meilleur compromis avec le plus faible nombre de Faux Positifs (64 cas) et une bonne maîtrise des Faux Négatifs (24 cas).

Par ailleurs, le seuil optimal passe de 0.18 à 0.39, indiquant une meilleure calibration du modèle, qui devient moins dépendant d'un seuil artificiellement bas.

Afin de compléter cette analyse, une évaluation quantitative des différentes configurations est présentée dans le Tableau 3-3.

Tableau 3-3 Comparaison des configurations

Configuration	Seuil	Acc.	Sens. (Recall)	Spec.	F1-Score	AUC
Baseline (BCE)	0.50	0,921	0,935	0,907	0,922	0,9787
	0.18	0,892	0,953	0,830	0,898	0,9787
Baseline + Augmentation	0.50	0,911	0,913	0,909	0,911	0,9769
	0.26	0,902	0,945	0,858	0,906	0,9767
FL + Augmentation	0.50	0,911	0,903	0,919	0,910	0,9765
	0.39	0,907	0,949	0,864	0,911	0,9765

3.4.1 Impact de la Data Augmentation

Les résultats obtenus avec le modèle baseline ont mis en évidence une certaine sensibilité du système aux variations de qualité d'image, en particulier lorsque les électrocardiogrammes présentent des artefacts de numérisation ou des dégradations physiques du support. Afin d'améliorer la capacité de généralisation du modèle face à ces variations, un pipeline de data augmentation a été introduit lors de la phase d'entraînement.

Les transformations appliquées visent à simuler différentes conditions d'acquisition susceptibles d'être rencontrées en pratique clinique. Elles incluent notamment des rotations légères, reproduisant une inclinaison lors de la capture de l'image, l'application d'un flou gaussien simulant une mise au point imparfaite ou un effet de numérisation, ainsi que des

variations de contraste et de luminosité, représentant les différences d'éclairage ou de conditions de scan.

Ces transformations augmentent la diversité visuelle du jeu d'entraînement et encouragent le modèle à apprendre des caractéristiques morphologiques intrinsèques du signal ECG, plutôt que de dépendre de propriétés spécifiques aux images numériques de haute qualité.





Figure 3-7 Échantillons d'entraînement après Data Augmentation

L'analyse des performances présentées dans le Tableau 3-3 montre que l'introduction de la data augmentation ne se traduit pas par une amélioration significative des métriques globales sur le jeu de test standard. Les valeurs d'AUC restent en effet très proches de celles observées avec le modèle baseline (≈ 0.97 – 0.98), indiquant que la capacité de discrimination du modèle est globalement conservée.

En revanche, l'impact de l'augmentation apparaît davantage au niveau de la stabilité comportementale du modèle. Les modèles entraînés avec augmentation nécessitent un ajustement du seuil décisionnel moins extrême pour atteindre une sensibilité élevée, ce qui suggère une distribution des probabilités prédictives plus structurée.

Ainsi, l'augmentation des données agit comme un mécanisme de régularisation implicite, limitant le surapprentissage sur les conditions idéales de capture et préparant le modèle à des variations visuelles plus importantes.



(a) Baseline

(b) Modèle Final

Figure 3-8 Comparaison des cartes Grad-CAM pour un ECG présentant des dégradations visuelles importantes (Patient 57655084, MI).

3.4.2 Introduction de la Focal Loss

Malgré les améliorations apportées par la data augmentation, certaines limites persistent dans le comportement décisionnel du modèle. L'analyse des probabilités prédictives du modèle baseline montre que certains exemples proches de la frontière de décision restent difficiles à classer, ce qui peut conduire à des prédictions incertaines ou à des niveaux de confiance élevés pour des classifications incorrectes.

Afin de mieux gérer ces cas ambigus, une troisième configuration expérimentale a été introduite, combinant la data augmentation avec l'utilisation de la **Focal Loss**. Contrairement à la **Binary Cross Entropy**, qui attribue le même poids à toutes les observations, la Focal Loss réduit l'influence des exemples faciles et concentre l'apprentissage sur les exemples difficiles ou mal classés.

Ce mécanisme est particulièrement pertinent dans l'analyse d'images ECG, où certaines observations présentent des caractéristiques morphologiques ambiguës ou des perturbations liées aux conditions d'acquisition. En renforçant l'apprentissage sur ces cas difficiles, la Focal Loss peut contribuer à améliorer la stabilité décisionnelle du modèle.

Dans cette étude, la Focal Loss est utilisée dans le scénario 3 en combinaison avec la data augmentation. L'objectif est d'évaluer son impact non seulement sur les performances globales du modèle, mais aussi sur la distribution des probabilités prédictives et la confiance associée

aux décisions, des aspects essentiels pour l'utilisation de systèmes d'aide au diagnostic en contexte clinique.

3.5 Analyse comparative du comportement probabiliste des modèles

L'impact de la Focal Loss est analysé en comparant les différentes configurations expérimentales définies précédemment : le modèle baseline et le modèle final intégrant la Focal Loss. L'objectif est d'évaluer si la focalisation du gradient sur les exemples difficiles, c'est-à-dire ceux pour lesquels la probabilité prédite est éloignée de la réalité, modifie la dynamique décisionnelle du modèle.

Au-delà des métriques de performance classiques telles que l'accuracy ou l'AUC, l'analyse du comportement probabiliste d'un modèle constitue un aspect important dans les systèmes d'aide au diagnostic médical. En effet, dans un contexte clinique, il ne suffit pas qu'un modèle produise une classification correcte : il est également essentiel que les probabilités associées aux prédictions reflètent de manière cohérente le niveau de confiance du système.

L'analyse probabiliste vise ainsi à examiner la distribution des probabilités prédictives, la confiance associée aux décisions du modèle, ainsi que la calibration des probabilités produites. Ces éléments permettent d'évaluer dans quelle mesure les scores générés par le modèle peuvent être interprétés comme des estimations fiables du risque de présence d'un infarctus.

Dans cette étude, trois analyses complémentaires ont été réalisées :

- L'analyse de la distribution des probabilités prédictives,
- L'analyse de la confiance des prédictions,
- L'évaluation de la calibration probabiliste à l'aide d'un diagramme de fiabilité et de l'Expected Calibration Error (ECE).

3.5.1 Distribution des probabilités prédictives

L'analyse de la distribution des probabilités prédictives permet d'examiner la manière dont le modèle sépare les deux classes (MI et NORM) dans l'espace probabiliste.

➤ **Modèle Baseline**

La Figure 3-9 présente la distribution des probabilités prédictives produites par le modèle baseline sur l'ensemble de test.




Figure 3-9 Distribution des probabilités prédictives du modèle Baseline.

On observe que les probabilités associées aux patients sains se concentrent majoritairement autour de valeurs proches de 0, tandis que les cas d'infarctus présentent des probabilités élevées, proches de 1. Cette distribution indique une bonne capacité de séparation entre les deux classes.

Toutefois, une zone de chevauchement apparaît dans la région intermédiaire des probabilités. Cette zone correspond aux cas les plus ambigus pour le modèle et explique la nécessité d'abaisser le seuil de décision à 0.18 afin d'optimiser la sensibilité diagnostique.

Cette observation suggère que, malgré une capacité de discrimination globale élevée, le modèle baseline présente encore une certaine incertitude dans certaines situations limites.

➤ **Modèle final**

La Figure 3-10 présente la distribution des probabilités prédictives pour le modèle final intégrant la Data Augmentation et la Focal Loss.




Figure 3-10 Distribution des probabilités prédictives du modèle final.

Comparativement au modèle baseline, la distribution des probabilités apparaît plus étalée et le seuil optimal se situe désormais autour de 0.39. Cette évolution traduit une modification du comportement probabiliste du modèle.

La séparation entre les classes reste clairement visible, mais les probabilités produites sont moins extrêmes. Cette caractéristique suggère que le modèle final adopte un comportement légèrement plus conservateur dans l'attribution de niveaux de confiance élevés.

Cette modification peut être interprétée comme un effet combiné de la data augmentation et de la Focal Loss, qui incitent le modèle à mieux prendre en compte les exemples difficiles présents dans l'espace de décision.

3.5.2 Analyse de la confiance des prédictions

Afin d'approfondir l'analyse probabiliste du modèle, nous avons également étudié la distribution des niveaux de confiance associés aux prédictions correctes et incorrectes.

Cette analyse permet d'évaluer si le modèle attribue des niveaux de confiance plus élevés aux prédictions correctes qu'aux erreurs, ce qui constitue une propriété importante pour l'interprétation des résultats.

Modèle Baseline

La Figure 3-11 présente la distribution des niveaux de confiance pour les prédictions correctes et incorrectes du modèle baseline.




Figure 3-11 Distribution de la confiance pour les prédictions correctes et incorrectes du modèle Baseline.

La distribution de la confiance pour le modèle baseline met en évidence une séparation partielle entre les prédictions correctes et incorrectes, mais avec des limites importantes.

Les prédictions correctes (courbe verte) sont fortement concentrées dans la zone des hautes confiances ($\approx 0.95 - 1.0$), ce qui indique que le modèle est capable d'identifier correctement une grande partie des cas avec un niveau de certitude élevé. Cette concentration traduit un comportement décisionnel affirmé.

Cependant, la distribution des erreurs (courbe rouge) présente une caractéristique importante : elle est relativement étalée et conserve une densité non négligeable dans des zones de confiance intermédiaire à élevée ($\approx 0.6 - 0.85$). Cela signifie que certaines prédictions incorrectes sont associées à des niveaux de confiance significatifs.

Le chevauchement entre les deux distributions, bien que limité, indique que le modèle peut être sur-confiant dans certaines situations, attribuant une probabilité élevée à des prédictions erronées. Ce phénomène est problématique dans un contexte clinique, car il peut conduire à des décisions incorrectes prises avec un fort degré de certitude.

Modèle final

La Figure 3-12 présente la même analyse pour le modèle final.




Figure 3-12 Distribution de la confiance pour les prédictions correctes et incorrectes du modèle final.

Pour le modèle final, la distribution des niveaux de confiance présente un comportement sensiblement différent, révélant une amélioration de la calibration du modèle.

La distribution des prédictions correctes (courbe verte) est plus étalée et moins concentrée dans les valeurs extrêmes. Contrairement au baseline, le modèle attribue moins fréquemment des probabilités proches de 1.0, ce qui reflète une réduction des prédictions excessivement confiantes.

Par ailleurs, la distribution des erreurs (courbe rouge) est davantage concentrée dans les faibles à moyennes confiances ($\approx 0.5 - 0.7$), avec une diminution notable de la densité dans les zones de forte confiance. Cela indique que les erreurs sont désormais associées à un niveau d'incertitude plus élevé.

Le chevauchement entre les deux distributions est globalement réduit dans les zones de haute confiance, ce qui traduit une meilleure séparation entre prédictions fiables et non fiables.

Ainsi, le modèle final adopte un comportement plus prudent et mieux calibré : il reste confiant lorsqu'il a raison mais évite d'être excessivement sûr lorsqu'il se trompe.

Cette évolution est cohérente avec l'objectif de la Focal Loss, qui met l'accent sur les exemples difficiles, et avec l'effet régularisateur de la data augmentation.

3.5.3 Calibration probabiliste du modèle

La calibration probabiliste évalue la cohérence entre les probabilités prédites par le modèle et la fréquence réelle d'occurrence des événements observés.

Un modèle parfaitement calibré devrait produire des probabilités reflétant fidèlement la probabilité réelle de l'événement. Par exemple, parmi les prédictions associées à une probabilité de 0.8, environ 80 % devraient correspondre à des cas réellement positifs.

Cette propriété est particulièrement importante dans les systèmes d'aide à la décision médicale, où les probabilités peuvent être utilisées pour guider l'interprétation clinique.

La calibration a été évaluée à l'aide de deux outils :

- Le diagramme de fiabilité (Reliability Diagram)
- La métrique Expected Calibration Error (ECE)

Modèle Baseline

La Figure 3-13 présente le diagramme de fiabilité du modèle baseline.




Figure 3-13 Diagramme de fiabilité du modèle Baseline.

L'erreur de calibration attendue est estimée à $ECE \approx 0.043$, indiquant une calibration globalement satisfaisante. La courbe empirique reste relativement proche de la diagonale représentant une calibration parfaite.

Cela signifie que les probabilités produites par le modèle baseline reflètent relativement bien la fréquence réelle des événements observés.

Modèle final

La Figure 3-14 présente le diagramme de fiabilité du modèle final.




Figure 3-14 Diagramme de fiabilité du modèle final.

Dans ce cas, l'erreur de calibration attendue est estimée à $ECE = 0.0862$, indiquant une légère dégradation de la calibration par rapport au modèle baseline.

Cette observation est cohérente avec certains travaux montrant que l'utilisation de la Focal Loss peut modifier la distribution des probabilités produites par le modèle. Bien que cette fonction de perte améliore souvent l'apprentissage sur les exemples difficiles, elle peut également conduire à des probabilités moins bien calibrées.

Malgré cette légère augmentation de l'ECE, la capacité de discrimination du modèle reste élevée et la séparation entre les classes demeure clairement visible.

3.6 Robustesse clinique du modèle

Performance par type de dégradation

La Figure 3-15 présente les performances du modèle en fonction du type de dégradation appliquée aux images ECG.




Figure 3-15 Fiabilité du diagnostic selon le type de dégradation.

L'analyse des résultats met en évidence une robustesse globale élevée du modèle face aux altérations visuelles :

- **Résilience aux dommages physiques du support :** Malgré la présence de taches simulant des moisissures ou de dégradations importantes du papier, le modèle maintient une accuracy supérieure à 85 %. Ce comportement suggère que le réseau parvient à ignorer en grande partie les artefacts non pertinents pour l'analyse du signal ECG.
- **Bonne performance sur les ECG numérisés :** Les images issues de scans couleur ou noir-et-blanc présentent des performances proches de 90,8 % d'accuracy, indiquant que le système peut être appliqué à des archives ECG numérisées sans perte significative de fiabilité.
- **Condition la plus complexe : photographie d'écran :** La capture d'un ECG affiché sur un écran d'ordinateur constitue la situation la plus difficile, avec une accuracy d'environ 84,5 %. Cette baisse relative peut être attribuée à des phénomènes de moirage et d'interférences visuelles générés par l'interaction entre les pixels de l'écran et le capteur de la caméra.

Dans l'ensemble, ces résultats montrent que le modèle final conserve des performances relativement stables malgré l'introduction de dégradations visuelles variées. Cette robustesse suggère que l'utilisation de techniques de data augmentation lors de l'entraînement a permis

au modèle d'apprendre des représentations visuelles plus invariantes aux perturbations d'acquisition.

Le modèle semble ainsi privilégier les structures morphologiques du tracé ECG, plutôt que des caractéristiques superficielles liées à la qualité de l'image. Ces observations renforcent l'hypothèse que l'approche proposée pourrait être adaptée à des scénarios réels d'acquisition d'ECG, où la qualité des images peut varier en fonction du support, du mode de numérisation ou des conditions de capture.




Figure 3-16 Visualisation Grad-CAM du modèle final sur différentes conditions de dégradation.

3.7 Démonstration du système CardioVision-MI

Afin de rendre le modèle de détection d'infarctus exploitable dans un contexte applicatif, une application web nommée CardioVision-MI a été développée. Cette plateforme permet aux professionnels de santé d'interagir avec le modèle d'apprentissage profond à travers une interface simple et structurée.

L'application offre plusieurs fonctionnalités principales : l'authentification sécurisée des utilisateurs, la gestion des patients, l'analyse automatisée d'images ECG et la génération de rapports d'analyse.

3.7.1 Authentification des utilisateurs

L'accès à la plateforme est sécurisé par un système d'authentification. Chaque utilisateur doit saisir ses identifiants afin d'accéder à son espace personnel. Ce mécanisme permet de limiter l'accès aux données médicales et constitue une première mesure de protection des informations sensibles.



Figure 3-17 Interface d'authentification de l'application

3.7.2 Tableau de bord

Après authentification, l'utilisateur accède au tableau de bord principal du système. Celui-ci fournit une vue synthétique de l'activité de la plateforme, incluant notamment le nombre de patients enregistrés, les analyses ECG réalisées et les résultats récents.




Figure 3-18 Tableau de bord de l'application

3.7.3 Gestion des patients

L'application intègre un module de gestion des patients permettant aux médecins d'enregistrer et d'organiser les dossiers médicaux. Chaque médecin dispose d'un espace personnel dans lequel il peut ajouter de nouveaux patients, consulter les dossiers existants et accéder à l'historique des analyses ECG.




Figure 3-19 Interface de gestion des patients

3.7.4 Analyse automatisée des ECG

La fonctionnalité centrale de l'application consiste à analyser automatiquement les images d'électrocardiogrammes à l'aide du modèle ConvNeXt entraîné dans cette étude.

Après importation d'une image ECG, le système fournit :

- La probabilité de présence d'un infarctus,
- Le diagnostic prédit,
- Ainsi qu'une estimation de la qualité de l'image.

Une visualisation Grad-CAM est également générée afin de mettre en évidence les régions du tracé ECG ayant influencé la décision du modèle.




Figure 3-20 Exemple d'analyse ECG avec visualisation Grad-CAM

3.7.5 Génération de rapports

Après l'analyse, l'application permet de générer automatiquement un rapport contenant les informations principales de l'examen, notamment le diagnostic prédit et la probabilité associée. Ce document peut être exporté afin d'être intégré au dossier médical du patient.

CardioVision-MI

Rapport d'analyse - 12/03/2026 12:17

Informations patient

Champ	Valeur
Nom	Soli Sino
Âge	23 ans
Sexe	Masculin
ID Patient	#1

Résultats de l'analyse

Métrique	Valeur
Diagnostic	Infarctus
Probabilité	94.4%
Qualité image	100%

Figure 3-21 Exemple de rapport généré par l'application

3.8 Conclusion partielle

Les expérimentations réalisées dans ce chapitre ont permis d'évaluer les performances et la robustesse du modèle ConvNeXt pour la détection d'infarctus à partir d'images ECG. Les résultats montrent une capacité de discrimination élevée ainsi qu'une bonne stabilité face à différentes dégradations d'images. L'implémentation de l'application web CardioVision-MI démontre par ailleurs la possibilité d'intégrer ce modèle dans un outil interactif d'aide au diagnostic destiné aux professionnels de santé.

Conclusion générale

Ce mémoire avait pour objectif d'explorer l'utilisation des techniques d'apprentissage profond pour la détection automatique de l'infarctus du myocarde à partir d'images d'électrocardiogrammes. Dans ce cadre, un modèle basé sur l'architecture ConvNeXt a été entraîné et évalué afin d'identifier automatiquement les signes d'infarctus sur des images ECG. Les expérimentations montrent que ce type d'approche permet d'obtenir de bonnes performances de classification tout en conservant une certaine robustesse face à différentes dégradations d'image. L'étude a également permis d'analyser le comportement probabiliste du modèle et d'explorer des stratégies d'apprentissage visant à améliorer sa stabilité. Le développement de l'application web CardioVision-MI a par ailleurs démontré la faisabilité de l'intégration du modèle dans un outil interactif d'aide au diagnostic destiné aux professionnels de santé.

Malgré ces résultats encourageants, certaines limites doivent être soulignées. Les expérimentations ont été réalisées principalement sur des bases de données expérimentales, qui ne reflètent pas nécessairement toute la diversité des situations rencontrées dans la pratique clinique. De plus, l'évaluation du modèle repose essentiellement sur des métriques issues de l'apprentissage automatique et n'a pas encore fait l'objet d'une validation clinique impliquant des spécialistes en cardiologie. L'application CardioVision-MI constitue enfin un prototype fonctionnel qui nécessiterait des développements supplémentaires avant une utilisation dans un environnement hospitalier réel.

Plusieurs perspectives peuvent être envisagées afin de prolonger ce travail. Une première direction consisterait à évaluer le modèle sur des ensembles de données ECG plus larges et issus de différents contextes cliniques. L'intégration d'informations cliniques complémentaires pourrait également améliorer la précision diagnostique du système. Enfin, l'évolution de la plateforme CardioVision-MI pourrait inclure l'analyse d'autres pathologies cardiaques et l'adaptation du système à des conditions d'acquisition variées afin de favoriser son utilisation dans des environnements médicaux réels.

Annexe A

Extraits de l'implémentation du modèle d'intelligence artificielle

A.1 Configuration des hyperparamètres

```
CONFIG = {  
    "seed": 32,  
    "epochs": 25,  
    "model_name": "convnext_small.fb_in22k_ft_in1k",  
    "img_size": 512,  
    "batch_size": 16,  
    "lr": 3e-5,  
    "weight_decay": 0.1,  
    "dropout": 0.6,  
    "patience": 7,  
    "device": torch.device("cuda" if torch.cuda.is_available() else "cpu"),  
    "n_classes": 1  
}
```

Figure 3-22 Configuration des hyperparamètres

A.2 Pipeline de prétraitement et de Data Augmentation

```
train_transform = transforms.Compose([  
    transforms.Resize((CONFIG['img_size'], CONFIG['img_size'])),  
    transforms.RandomPerspective(distortion_scale=0.2, p=0.4),  
    transforms.RandomRotation(degrees=8),  
    transforms.RandomHorizontalFlip(p=0.5),  
    transforms.RandomAffine(degrees=0, translate=(0.05, 0.05), scale=(0.95, 1.1)),  
    transforms.ColorJitter(brightness=0.4, contrast=0.4, saturation=0.1),  
    transforms.RandomAdjustSharpness(sharpness_factor=2, p=0.3),  
    transforms.RandomApply([  
        transforms.GaussianBlur(kernel_size=3, sigma=(0.1, 1.5))  
    ], p=0.3),  
    transforms.RandomGrayscale(p=0.1),  
    transforms.ToTensor(),  
    transforms.Normalize([0.485, 0.456, 0.406], [0.229, 0.224, 0.225])  
])
```

Figure 3-23 Pipeline de prétraitement et de Data Augmentation

A.3 Implémentation de la fonction de perte Focal Loss utilisée lors de l'entraînement

```
class FocalLoss(nn.Module):
    def __init__(self, alpha=0.25, gamma=2.0, reduction='mean'):
        super(FocalLoss, self).__init__()
        self.alpha = alpha
        self.gamma = gamma
        self.reduction = reduction

    def forward(self, inputs, targets):

        BCE_loss = F.binary_cross_entropy_with_logits(
            inputs,
            targets,
            reduction='none'
        )

        pt = torch.exp(-BCE_loss)

        F_loss = self.alpha * (1 - pt)**self.gamma * BCE_loss

        if self.reduction == 'mean':
            return torch.mean(F_loss)
        else:
            return torch.sum(F_loss)
```

Figure 3-24 Implémentation de la fonction de perte Focal Loss

A.4 Boucle d'entraînement

```
for epoch in range(CONFIG['epochs']):

    model.train()

    for imgs, labels in train_loader:

        imgs = imgs.to(CONFIG['device'])
        labels = labels.to(CONFIG['device'])

        optimizer.zero_grad()

        outputs = model(imgs)

        loss = criterion(outputs, labels)

        loss.backward()

        optimizer.step()
```

Figure 3-25 Boucle d'entraînement

Annexe B

Interface de la plateforme CardioVision-MI

B.1 Interface principale




Figure 3-26 Interface principale

B.2 Gestion des rendez-vous




Figure 3-27 Interface de gestion des rendez-vous

B.3 Statistiques




Figure 3-28 Interface des Statistiques

Bibliographie

- [1] O.m.d.l. santé, "Maladies cardiovasculaires," 2024. [Online]. Available: https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_1. [Accessed 8 Juillet 2025].
- [2] J. Giorgetta, "C'est quoi une ischémie ?," *Journal des Femmes (Santé)*, 21 Mars 2023.
- [3] P. G. Aublin, "Analyse avancée de signaux ECG acquis en IRM," Université de Lorraine, Vandoeuvre-lès-Nancy, 2023.
- [4] George B. Moody PhysioNet Challenge, "Digitization and Classification of ECG Images: The George B. Moody PhysioNet Challenge 2024," 20 Septembre 2024.
- [5] K. E. HOUARI, "Modélisation et imagerie électrocardiographiques," Rennes, 2018.
- [6] K. DJABELLA, "Modélisation de l'activité électrique du coeur et de sa régulation par le système nerveux autonome," Orsay, 2008.
- [7] Wapcaplet, "Diagram of the Human Heart," 2006.
- [8] Usien6, "Phases of the cardiac cycle," 2017.
- [9] Animaniac, "Conduction System of the Heart," 2006.
- [10] M. L. MESSIOUD, "Classification des signaux ECG en utilisant les réseaux de neurones," Guelma, 2019.
- [11] J. Furst, "Recording a 12 lead ECG/EKG," 2017.
- [12] PP1 and WORLD ASSOCIATION of PLANETARIAN HEALTH, Anatomie et Physiologie Humaines, World Association of Planetarian Health.
- [13] M. C. d. M. D. Guerra, A. G. d. S. Rezende, T. A. Magalhães and e. al, "Detection and Location of Myocardial Infarction Using Electrocardiogram: Validation by Cardiovascular Magnetic Resonance Imaging.," *Arq Bras Cardiol*, 2024.
- [14] Designua, "Dreamstime," [Online]. Available: <https://fr.dreamstime.com/%C3%A9lectrocardiographie-ecg-ekg-d-coeur-rythme-sinus->

normal-st-infarctus-myocardique-%C3%A9lev%C3%A9-ischemia-d%C3%A9pression-image233813360. [Accessed 14 Février 2026].

- [15] University of Utah Health, "Lesson 9: Recognition of Myocardial Infarction," 2026. [Online]. Available: <https://library.med.utah.edu/kw/ecg/>.
- [16] Hôpitaux Universitaires de Genève (HUG), "Protocole 2.8 : ECG 12 dérivations," Brigade Sanitaire Cantonale, Genève, 2013.
- [17] S. S. Q. a. R. G. Afkhami, "ECG arrhythmia classification using time frequency distribution techniques," *Biomed. Eng. Lett.*, vol. vol. 7, no. 4, p. pp. 325–332, 2017.
- [18] M. K. E. A. M. A. A. A. Rawi, "Deep learning models for multilabel ECG abnormalities classification: A comparative study using TPE optimization," *Journal of Intelligent Systems*, vol. 32, no. 1, 2023.
- [19] Q. Z. K. Z. A. S. D. S. S. Z. T. Rasti, "ECG-Based Arrhythmia Detection by a Shallow CNN Model," *Series Cardiol Res.*, vol. 6, 2024.
- [20] Y. W. a. Y. Z. Y. Zhang, "A comprehensive review of deep learning in ECG classification," *Journal of Healthcare Engineering*, vol. vol. 2020, pp. pp. 1-12, 2020.
- [21] A. Fall, "Interpretability of Neural Networks applied to Electrocardiograms: Translational Applications in Cardiovascular Diseases," Paris, France, 2023.
- [22] O. J. Msigwa., "Data Science and ML (Part 30): The Power Couple for Predicting the Stock Market, Convolutional Neural Networks (CNNs) and Recurrent Neural Networks (RNNs)," *MetaTrader 5*, 30 Septembre 2024.
- [23] X. Wang, R. Nadarajah, Z. Zhang and D. Wong, *Knowledge Augmentation via Synthetic Data: A Framework for Real-World ECG Image Classification*, a. (. University), Ed., 2025.
- [24] S. Bdir, M. Jaber and M. Qneibi, "Artificial Intelligence for Myocardial Infarction Detection via Electrocardiogram: A Scoping Review," *Journal of Clinical Medicine*, 2025.

- [25] W.-C. Liu, C.-S. Lin, C.-S. Tsai and C. Lin, "A deep learning algorithm for detecting acute myocardial infarction," *EuroIntervention*, vol. 17, pp. 765-773, 2021.
- [26] S. Dhandapani, H. Somasundaram and T. Angamuthu, "Hybrid deep learning framework for heart disease prediction using ECG signal images," *Scientific Reports (Nature)*, vol. 15, no. 33922, 2025.
- [27] S. Rahman, S. Pal, J. Yearwood and C. Karmakar, "Robustness of Deep Learning models in electrocardiogram noise detection and classification," *Computer Methods and Programs in Biomedicine*, vol. 253, 2024.
- [28] M. A. Reyna, Deepanshi, J. Weigle and Sa, "ECG-Image-Database: A Dataset of ECG Images with Real-World Imaging and Scanning Artifacts," Septembre 2024. [Online]. Available: <https://arxiv.org/abs/2409.16612>.
- [29] P. Wagner, N. Strodthoff, R. D. Bousseljot, D. Kreiseler, F. I. Lunze, . W. Samek and t. Schaeffter, "PtB-XL, a large publicly available," *Scientific Data*, vol. 7, 2020.
- [30] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li and L. Fei-Fei, "ImageNet: A Large-Scale Hierarchical Image Database," in *2009 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Miami, FL, USA, 2009.
- [31] Z. Liu, H. Mao, C.-Y. Wu, C. Feichtenhofer, T. Darrell and S. Xie, "A ConvNet for the 2020s," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022.
- [32] H. Narotamo, M. Dias, R. Santos, A. V. Carreiro, H. Gamboa and M. Silveira, "Deep learning for ECG classification: A comparative study of 1D and 2D representations and multimodal fusion approaches," *Biomedical Signal Processing and Control*, vol. 93, 2024.
- [33] Y. Zhang, A. Xu, D. Lan, X. Zhang, J. Yin and H. H. Goh, "ConvNeXt-based anchor-free object detection model for infrared image of power equipment," *Energy Reports*, vol. 9, 2023.

- [34] T.-Y. Lin, P. Goyal, R. Girshick, K. He and P. Dollár, "Focal Loss for Dense Object Detection," *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2017.
- [35] W. J. Youden, "Index for rating diagnostic tests," *Cancer*, vol. 3, pp. 32-35, 1950.
- [36] JUnit.org. [Online]. Available: <http://www.junit.org>. [Accessed 2 Janvier 2019].
- [37] I. d. c. d. l. d'Ottawa, "Les arythmies (anomalies du rythme cardiaque)," 2015. [Online]. Available: <https://www.ottawaheart.ca/fr/maladie-du-c%C5%93ur/les-arythmies-anomalies-du-rythme-cardiaque>. [Accessed 8 Juillet 2025].
- [38] B. KHADDOUMI, "Analyse et modélisation de l'activité électrique du coeur dans le cas de pathologies ventriculaires," Nice, 2005.
- [39] K. E. Houari, "Modeling and imaging of electrocardiographic activity," Rennes, France, 2018.
- [40] N. M. Ghahjaverestan, "Early detection of cardiac arrhythmia based on Bayesian methods from ECG data," Rennes, France, 2015.
- [41] F. Z. Ismail, "Classification Du Signal ECG avec le Deep Learning," Blida, Algérie, 2023.
- [42] B. Khaddoumi, "Analyse et modélisation de l'activité électrique du coeur dans le cas de pathologies ventriculaires," Nice, France, 2005.
- [43] H. F. S. L. O. Y. H. J. H. T. M. A. U. Rajendra Acharya, "Application of Deep Convolutional Neural Network for Automated Detection of Myocardial Infarction Using ECG Signals," *Information Sciences*, vol. Vol. 423, p. pages 248–261, 2018.
- [44] T. O. F. C. Kuba Weimann, "Transfer learning for ECG classification," *Scientific Reports*, vol. Vol. 11, no. 1, p. p. 11624, 2021.
- [45] B. Amar, "Classification des signaux EGC avec un système-multi-agent neuronale.," Tlemcen, Algérie, 2012.

- [46] N. Chibout, "Physiologie de l'appareil cardio-vasculaire (Partie 1) : physiologie cardiaque," 2020. [Online]. Available: https://drive.google.com/open?id=1-mbbxN4sfsqDeauaHOZ2_EpIAEEzVZyw.
- [47] P. v. Dam, "Non-Invasive Imaging of Cardiac Activation and Recovery.," 2009.
- [48] CapRetraite, "Tout sur l'arythmie cardiaque : symptômes, cause et traitement," 2025.
- [49] K. C. Hari Mohan Rai, "Hybrid CNN-LSTM deep learning model and ensemble technique," 2021.
- [50] "Typical CNN architecture," 2017.
- [51] R. N. Sweis and A. Jivan, "Infarctus du myocarde aigu," Juillet 2024. [Online]. Available: <https://www.msmanuals.com/fr/professional/troubles-cardiovasculaires/coronaropathie/infarctus-du-myocarde-aigu>.
- [52] I. Loshchilov and F. Hutter, "Decoupled Weight Decay Regularization," *International Conference on Learning Representations (ICLR)*, 2019.
- [53] P. Wagner, N. Strodthoff, R.-D. Boussejot, D. Kreiseler, F. I. Lunze, W. Samek and T. Schaeffter, "PTB-XL, a large publicly available electrocardiography dataset," *Scientific Data*, vol. 7, p. 154, 14 Mai 2020.